



Sveučilište u Zagrebu

FILOZOFSKI FAKULTET

Ivan Tomić

**ULOGA SNAGE DISTRAKTORA U
VIDNOM RADNOM PAMĆENJU**

DOKTORSKI RAD

Zagreb, 2019.



Sveučilište u Zagrebu

FILOZOFSKI FAKULTET

Ivan Tomić

**ULOGA SNAGE DISTRAKTORA U
VIDNOM RADNOM PAMĆENJU**

DOKTORSKI RAD

Mentor:

prof. dr. sc. Dragutin Ivanec

Zagreb, 2019.



University of Zagreb

FACULTY OF HUMANITIES AND SOCIAL SCIENCES

Ivan Tomić

**THE ROLE OF DISTRACTOR STRENGTH
IN VISUAL WORKING MEMORY**

DOCTORAL THESIS

Supervisor:
prof. dr. sc. Dragutin Ivanec

Zagreb, 2019

O mentoru

Prof. dr. sc. Dragutin Ivanec rođen je 1965. godine u Kladarama. Srednju školu završio je u Virovitici. Dodiplomski studij psihologije završio je u Odsjeku za psihologiju Filozofskog fakulteta u Zagrebu 1989. godine. Na istom je fakultetu magistrirao 1994. te doktorirao 2002. godine. U znanstveno nastavno zvanje redovnog profesora izabran je 2016. godine.

Od 1990. godine zaposlen je u Odsjeku za psihologiju pri Katedri za eksperimentalnu psihologiju. U okviru redovite nastave na Preddiplomskom studiju psihologije nositelj je kolegija *Psihologijski praktikum I*, a od ak. god. 2009/10. i kolegija *Statistika u psihologiji I*, i *Statistika u psihologiji II*, te izbornog kolegija kolegija *Psihologija boli*. Na Diplomskom studiju psihologije drži kolegij *Složeni nacrti istraživanja*. Na Doktorskom studiju psihologije predaje kolegij *Složeni eksperimentalni nacrti istraživanja i statističke analize*, te izborni kolegij *Suvremena pristupi u istraživanju placebo učinka*. Do sada je bio mentorom petorici studenata koji su obranili doktorat.

Predavao je na nekoliko fakulteta i visokih škola: na Visokoj zdravstvenoj školi sudjelovao je u izvođenju nastave za studente medicine iz kolegija *Psihologija boli* i kolegija *Stres, zdravlje i bolest*. Dvije akademske godine održavao je nastavu iz kolegija *Statistika u psihologiji* na Odsjeku za psihologiju Filozofskog fakulteta u Sarajevu, a od 1998. do 2005. predavao je kolegij *Statistika* na Visokoj školi za sigurnost na radu. Na Filozofskom fakultetu u Osijeku pri Katedri za psihologiju održavao sam nastavu iz kolegija *Uvod u deskriptivnu statistiku* i *Psihologija boli*. U ak. god. 2008/09. održavao je nastavu iz kolegija *Uvod u deskriptivnu i inferencijalnu statistiku* te *Osnove inferencijalne statistike* u Odjelu za psihologiju Sveučilišta u Zadru.

Objavio 41 znanstveni rad, četiri priloga u knjigama iz područja zdravstvene psihologije i četiri stručna teksta. Koautor je sveučilišnog udžbenika ih područja statistike u društvenim znanostima. Sudjelovao je više od sedamdeset međunarodnih i domaćih znanstvenih i stručnih skupova. Znanstveno-istraživački interes dominantno se veže uz područja osjetne i kognitivne psihologije te uloge psiholoških čimbenika u osjetu boli.

Član je Hrvatskog psihološkog društva, te član znanstvenog komiteta organizacije psihologa regije Alpe-Jadran.

Sažetak

U posljednjih desetak godina, spoznaje o funkcioniranju vidnog radnog pamćenja (VRP) iz temelja su promijenjene pojavom modela resursa VRP-a. Pretpostavka ove skupine modela jest kako je VRP ograničen skup resursa koji se kontinuirano dijeli između svih podražaja koji se pamte, bez pretpostavke o postojanju limita u broju podražaja na koje se resursi mogu podijeliti. Porastom broja podražaja koji se pamti smanjuje se količina resursa pridana svakom podražaju, a samim time i reprezentacijska snaga svakog podražaja. Ova pretpostavka potvrđena je nalazima kako preciznost dosjećanja kontinuirano pada s porastom broja podražaja koji se pamti. Premda modeli resursa imaju jasne pretpostavke o ulozi količine resursa kojom je neki podražaj kodiran u preciznosti dosjećanja, otpornost snažnijih reprezentacija na perceptivne distraktore gotovo je neistraženo pitanje. Intuitivno, mogućnost zadržavanja zapamćenih informacija uslijed distraktora ovisi o snazi reprezentacija tih informacija, pri čemu će snažnije reprezentacije u manjoj mjeri biti narušene distraktorima. Druga važna odrednica otpornosti reprezentacija VRP-a na perceptivne distraktore je snaga samih distraktora.

U ovom istraživanju željeli smo sustavno ispitati ulogu ova dva čimbenika - snage distraktora i snage reprezentacija u VRP-u - na preciznost dosjećanja u zadatku kontinuirane procjene u VRP-u. U eksperimentu 1 snaga reprezentacije manipulirana je variranjem broja podražaja koji se pamti i dostupnim vremenom kodiranja. U eksperimentu 2a nakon kodiranja podražaja jednom je podražaju dan prioritet za dosjećanje. U eksperimentu 2b tijekom faze zadržavanja pažnja je privremeno usmjerena na jedan od zapamćenih podražaja s ciljem osvježavanja njegove reprezentacije. U posljednjem, eksperimentu 3, distraktori su prikazivani tijekom različitih faza obrade podražaja (kodiranja, zadržavanja, dosjećanja) uz pretpostavku kako je snaga reprezentacije najslabija prije no što kodiranje završi. Snaga perceptivnih distraktora u svim eksperimentima manipulirana je kao vrijeme prikaza distraktora i to na tri razine (bez distraktora, slabi distraktor, snažni distraktor).

Rezultati su pokazali kako snaga reprezentacije ima važnu ulogu u zaštiti reprezentacije od distraktora. Dosjećanje podražaja kojima je pridano više resursa uslijed pamćenja manjeg broja podražaja i dužeg vremena kodiranja (eksperiment 1), koji su označeni kao prioritetni za dosjećanje (eksperiment 2a), koji su osvježeni tijekom faze zadržavanja (eksperiment 2b), te kojima faza kodiranja nije ometena (eksperiment 3), bilo je preciznije i uslijed prikaza distraktora. Uloga snage distraktora je potvrđena, no bila je kompleksna i ovisila je o načinu na koji su reprezentacije osvježene. Model mješovitih distribucija koji pretpostavlja kako se dosjećanje može opisati točnim dosjećanjima, pogreškama zamjene, intruzijama i pogađanjem, dobro je pristajao podacima. Najkonzistentnije promjene uočene su u vjerojatnosti točnog dosjećanja. Važno, intruzije su se pokazale sastavnom vrstom pogrešaka u svim eksperimentima.

Summary

Introduction

Our environment is overloaded with visual information, with only a fraction of them necessary for an ongoing task. What determines the success of performing everyday tasks in such an environment? Visual working memory (VWM) is considered a vital component of most complex behaviours, but previous studies provided evidence of its susceptibility to irrelevant visual information, i.e. distractors. When is VWM impervious to distractors? VWM is best described as a highly limited resource that is flexibly shared among items in a visual scene. As the number of items increases, the amount of resources allocated to each item decreases, leading to a decline in strength (i.e. quality) of memory representations, and consequently to less precise recall of each item. This finding is consistent with a resource model of VWM and has been highlighted as a hallmark observation in VWM studies. An alternative view is provided by the influential "slot" model of VWM which claims that VWM is limited with a fixed maximum number of items that can be held in memory at one time. Moreover, according to this model, an item is either represented in its entirety in a memory slot or not stored at all. Strength of memory representation is therefore almost completely neglected in this type of model. However, investigation of the role of representation strength, besides the well known set size effect, has been limited even in studies motivated by the resource model. It is an intuitive prediction that memorandum strength should influence task performance. For example, our ability to maintain relevant information in the presence of distracting visual input should depend on the strength of memoranda, with stronger representations suffering less from irrelevant visual input. Here we thoroughly investigated the roles of strength of representations in VWM and distractor strength.

Method

To this end, we conducted four experiments ($N = 64$) in which we systematically manipulated the strength of VWM representations and the strength of distractors. We employed a delayed-estimation task with continuous report, wherein subjects memorized colour stimuli. We manipulated strength of representation by: manipulating set size and encoding time (experiment 1), prioritizing one item for recall (experiment 2a), refreshing a representation of a single item during maintenance (experiment 2b), or interrupting memory phases before and after a stable representation was formed (experiment 3). After showing a memory array but before recalling one of the memorized items, irrelevant visual stimuli were shown. Simultaneously with memorandum strength, we manipulated distractor strength (no distractors, weak distractors, strong distractors).

Results

In all experiments we consistently found evidence that strength of memoranda serves a protec-

tive role against visual distractors. Regardless of the method used to manipulate memoranda strength, recall of stronger memoranda was less vulnerable to distractors. On the other hand, the effect of distractor strength showed a complex pattern which differed between experiments and depended on the manipulation of VWM representation strength. Next, we fit the data with a mixture model which assumes that the recall error distribution is a mixture of target recall, swap errors, intrusions, and guesses. This model captured the data well and showed better fit than the alternative *normal + uniform* model. When analyzing parameters of this model the most consistent manipulation dependent changes were observed on the target recall parameter. Intrusions were observed in all experiments. Interestingly, they depended more on VWM representation strength than on distractor strength.

Conclusion

This study revealed that strength of memoranda in VWM serves a protective role against visual distractors, making any addition of mechanisms of memoranda protection or distractor inhibition unnecessary. However, we showed that distractors, regardless of their strength, are able to penetrate VWM and lead to a decrease in recall precision. These findings are consistent with a resource conceptualisation of VWM where representational strength (i.e. the amount of allocated resources) plays a crucial role in ability to perform a task.

Ključne riječi: Vidno radno pamćenje, snaga reprezentacija, snaga distraktora, model mješovitih distribucija

Key words: Visual working memory, strength of representations, strength of distractor, mixture model

Sadržaj

1	Uvod	1
1.1	Vidno radno pamćenje	1
1.2	Pohrana u vidnom radnom pamćenju	2
1.2.1	Modeli utora	3
1.2.2	Modeli resursa	9
1.2.3	Neuralna osnova vidnog radnog pamćenja	17
1.2.4	Neuralni modeli vidnog radnog pamćenja	21
1.3	Interferencija u vidnom radnom pamćenju	25
1.4	Snaga distraktora	35
1.5	Snaga reprezentacija u vidnom radnom pamćenju	40
1.6	Broj zapamćenih podražaja	40
1.7	Vrijeme kodiranja	44
1.8	Prioritetnost i osvježavanje reprezentacija u pamćenju	47
1.9	Faza obrade	53
2	Cilj istraživanja	58
3	Istraživački problemi i hipoteze	60
4	Metoda	62
4.1	Sudionici	62
4.2	Zadatak kontinuirane procjene	62
4.3	Podražajni materijal	63
4.4	Postupak	64
4.4.1	Ekperiment 1	64

4.4.2	Eksperiment 2	66
4.4.3	Eksperiment 3	68
4.5	Strategija analize podataka	70
5	Rezultati i rasprava	74
5.1	Eksperiment 1	74
5.2	Eksperiment 2a	85
5.3	Eksperiment 2b	91
5.4	Eksperiment 3	96
6	Opća rasprava	102
7	Zaključak	119
8	Literatura	120
9	Životopis	150
10	Popis objavljenih radova	151

1 Uvod

1.1 Vidno radno pamćenje

Za većinu ljudi, obavljanje svakodnevnih zadataka bez korištenja vidnih informacija gotovo je nezamislivo. Vid je dominantno ljudsko osjetilo, zaslužno za obradu većine doživljenih podražaja i informacija (D. Stokes, Matthen i Biggs, 2014). Sposobnost vida nemoguća je bez pokreta očima koji su ujedno i dominantan ljudski pokret, češći od otkucaja srca (Carpenter, 2000). Vidna područja u mozgu koja omogućavaju osjet vida i vidnu percepciju imaju oštrinu i preciznost obrade informacija veću od većine drugih specijaliziranih mozgovnih područja (Serenes, 2016). Pohrana vidnih informacija u terminima vremenskog zadržavanja varira od trenutnog, tzv. ikoničkog pamćenja (Sperling, 1960) pa sve do trajnog, tzv. dugoročnog pamćenja (Brady, Konkle i Alvarez, 2011). Ovakav sažeti opis tek djelomično zahvaća sposobnosti, ulogu i zadatke ljudskog vidnog sustava. Ovaj sustav podrazumijeva cijeli orkestar neuralnih područja i kognitivnih procesa koji omogućuju njegovo neprekidno funkcioniranje kakvo većina nas svakodnevno iskusi. Zamislite se u nekoj svakodnevnoj situaciji poput nalaženja s prijateljem usred trga prepunog ljudi. Kako vidne informacije naučene prije mnogo vremena (npr. izgled prijatelja) i trenutno vidno perceptivno iskustvo (npr. izgled trga i stalna promjena prisutnih ljudi) upravljaju našim ponašanjem, prije svega pokretima očima, kako bismo uspješno integrirali informacije u mozgu i uspješno obavili trenutni zadatak te pronašli prijatelja? Obavljanje ovakvog zadatka zahtjeva koordinaciju velikog broja kognitivnih procesa, a najvažniji od njih je vidno radno pamćenje (VRP) (Ma, Husain i Bays, 2014).

Vidno radno pamćenje je naziv za proces kratkotrajnog i aktivnog zadržavanja vidnih informacija (Bays, 2015; Brady i sur., 2011; D'Esposito i Postle, 2015; Ma i sur., 2014). Najšire rečeno, funkcija VRP-a jest kratkotrajno zadržavanje vidnih informacija nakon što one nestanu iz osjetnog sustava, te obrada tih informacija kako bismo ih mogli koristiti za obavljanje trenutnog zadatka. Pritom, VRP prima informacije te je u interakciji s perceptivnim procesima (Tsubomi, Fukuda, Watanabe i Vogel, 2013) i ikoničkim pamćenjem (Hollingworth, Matsukura i Luck, 2013; Irwin, 1991), dugoročnim pamćenjem (Ranganath i Blumenfeld, 2005; Schon, 2004; Schurgin, 2018) te posebno pažnjom (Fougnie, 2009). Istovremeno, VRP relativno samostalno raspolaže vrlo specifičnim resursima za obradu isključivo vidnih informacija. Konkretno, dobro je potvrđen nalaz kako VRP može funkcionirati samostalno i neovisno o prostornom ili verbalnom radnom pamćenju (Hecker i Mapperson, 1997; Klauer i Zhao, 2004; Logie i Marchetti, 1991; vidi Morey, 2018).

Dvije možda najvažnije karakteristike VRP-a odnose se na njegova ograničenja. Prvo, VRP je vrlo ograničenog kapaciteta, što znači da simultano može zadržati tek manju količinu

informacija, a da one pritom budu korisne za upotrebu (Bays, 2015). Drugo, VRP je ograničeno vremenom i bez novog senzornog podraživanja, vidne informacije može zadržati tek kratko (Pertzov, Manohar i Husain, 2017; Rademaker, Park, Sack i Tong, 2018). Drugim riječima, sustav za obradu informacija poput radnog pamćenja suočava se s nekoliko izazova: koje informacije, od pregršt njih, zapamtiti, te kako ih zadržati do kraja obavljanja zadatka, naročito uslijed novih senzornih ulaza. To su pitanja pohrane i zaboravljanja, te specifično zaboravljanja uslijed interferencije.

1.2 Pohrana u vidnom radnom pamćenju

Prvi zadatak VRP-a jest da pohrani informacije iz okoline potrebne za uspješno obavljanje zadatka. Drugim riječima, kratkotrajno senzorno podraživanje potrebno je pretvoriti u stabilnu i vjernu reprezentaciju podražaja koja sadrži dovoljno bitnih informacija i omogućava kognitivnu obradu sličnu onoj kakvu omogućava perceptivno iskustvo na temelju kojeg je reprezentacija nastala. Imajući na umu kako je VRP ograničeno kapacitetom, a vidna okolina bogata informacijama, VRP ne može pohraniti detaljnu presliku okoline, već samo dio dostupnih informacija. To predstavlja svojevrsan izazov i prvo pitanje na koje svaki model VRP-a mora moći odgovoriti jest kakva je priroda pohrane podražaja u VRP-u odnosno kako se ograničeni kapacitet koristi za pohranu veće količine informacija.

Dvije široke skupine modela VRP-a ponudile su objašnjenje na koji način VRP pohranjuje informacije. Tradicionalni modeli VRP-a pretpostavljaju kako ljudi pamte manji broj cjelovitih informacija (Luck i Vogel, 1997; Pashler, 1988). Procjene poput Millerovog (Miller, 1956) magičnog broja 7 ili Cowanovog (Cowan, 2001, 2005) broja 4 imaju svoje uporište upravo u tradicionalnim teorijama RP. Ova ideja vrlo je intuitivna, a samim time i primamljiva: ako je kapacitet VRP-a (K_{\max}) veći od broja informacija koje osoba treba pohraniti, tada će sve informacije biti pohranjene; ako je broj vidnih podražaja koje je potrebno pohraniti veći od K_{\max} tada će VRP pohraniti broj informacija jednak K_{\max} dok ostatak informacija neće biti pohranjen. Nakon što se u VRP pohrani K_{\max} , s daljnjim porastom broja vidnih elemenata raste broj nezapamćenih informacija. Modeli koji dijele ovu ideju o prirodi pohrane nazivaju se *modeli utora* (engl. *slot models*). Ukratko, modeli utora predlažu gornju granicu informacija koju osoba može pohraniti. I dok neke starije formulacije modela utora (Luck i Vogel, 1997; Pashler, 1988) predlažu kako pamćenje funkcionira po principu "sve ili ništa", tj. informacije su pohranjene u VRP u cijelosti ili nisu pohranjene uopće, novije verzije hipoteze utora opisuju VRP puno fleksibilnijim, dopuštajući variranje u kvaliteti pohranjenih informacija (Zhang i Luck, 2008).

Druga široka skupina modela VRP-a, modeli resursa (engl. *resource models*), dijele s modelima utora pretpostavku o ograničenosti kapaciteta VRP-a, no pretpostavlja kako VRP točnije možemo opisati kao ograničenu količinu resursa koji se fleksibilno dijele između podražaja koji se pamte (Ma i sur., 2014). I za modele resursa ključna odrednica efikasnosti VRP-a je broj elemenata koji osoba može pohraniti. Pritom, ovi modeli pretpostavljaju kako s porastom informacija koje se pamte pada preciznost reprezentacija zapamćenih elemenata (Bays i Husain, 2008; van den Berg, Shin, Chou, George i Ma, 2012; Wilken i Ma, 2004). Modeli resursa imaju snažno uporište u neuralnim istraživanjima te je jedan od središnjih koncepata ovih modela postojanje reprezentacijskog šuma kao sastavnog dijela svake reprezentacije (Bays, 2015). Specifično, ovi modeli pretpostavljaju kako preciznost pamćenja vrlo malog broja podražaja, npr. i samo jednog podražaja, nikada nije savršena.

1.2.1 Modeli utora

Klasičan rad, često navođen kao potvrda modela utora u VRP-u proveli su Luck i Vogel (1997). U tom istraživanju korišten je zadatak detekcije promjene te je variran broj podražaja (oboje-nih kvadrata) koje su sudionici morali pamtit. U zadatku detekcije promjene sudionicima se najprije prikaže određen broj vidnih podražaja koji moraju zapamtiti, a nakon kratkog perioda nakon nestanka tih podražaja, prikazuje im se tzv. testni ekran koji sadrži ili identične informacije kao i prikaz za pamćenje ili jednu izmijenjenu informaciju. U prvom slučaju od sudionika se očekuje da odgovore kako nije došlo do promjene, dok se u drugom slučaju očekuje da točno detektiraju kako testni ekran po svim karakteristikama ne odgovara prikazu za pamćenje. Uradak u ovom zadatku ovisi o tome koliko informacija između prikaza za pamćenje i testnog ekrana moramo usporediti da bismo donijeli odluku. Provedeno istraživanje je pokazalo kako je točnost detekcije stabilna kada sudionici pamte manje od 3 ili 4 podražaja, dok s naknadnim povećanjem broja podražaja koji se pamti točnost detekcije kontinuirano pada. Nadalje, u dodatnim eksperimentima, kompleksnost vidnih podražaja koji su se pamtili nije mijenjala uradak, a procjene od otprilike 4 pohranjena podražaja dobivene su i kada se svaki podražaj sastojao od nekoliko boja. Autori su ove nalaze interpretirali kao dokaz ograničenih kapaciteta VRP-a te zaključili kako je pad u uratku odraz prelaska maksimalnog mogućeg broja podražaja koji se može upamtiti (K_{max}). I druga istraživanja koristeći iste ili slične eksperimentalne paradigme došli su do istog zaključka i opisali VRP kao spremnik koji može pohraniti između 3 i 4 vidna objekta (Saults i Cowan, 2007).

Rouder i sur. (2008) proveli su rigorozniji test modela utora koristeći zadatak detekcije promjene. Ako je kapacitet VRP-a odraz neke stabilne sposobnosti pamćenja, tada njegove procjene ne bi trebale varirati ovisno o korištenom broju podražaja za pamćenje u eksperimentu

ili vjerojatnosti da se na testnom ekranu desila promjena. Autori su u eksperimentu varirali broj elemenata koji se pamti te kriterij odlučivanja, i to tako da su manipulirali vjerojatnošću da se na testnom ekranu dogodi promjena. Procjene kapaciteta VRP-a bile su konzistentne neovisno o broju podražaja koji se pamti ili vjerojatnosti da se na testnom ekranu dogodi promjena. Osim toga, procjene prosječnog kapaciteta pamćenja bile su u skladu s prethodnim istraživanjima i pokazivale su da su sudionici pamtili oko 3 vidna elementa. Osim toga, autori su osmislili matematički model uratka u zadatku i procijenili pristajanje modela podacima. Model utora, ili kako ga autori nazivaju "sve-ili-ništa", pokazao je dobro pristajanje podacima, reproducirajući pretpostavljeni odnos točnih i netočnih detekcija promjene za određeni K_{max} i broj elemenata koji se pamti.

Unazad desetak godina modeli utora postali su mnogo fleksibilniji od originalnih verzija tih modela. Razlog tome prvenstveno je uvođenje novih paradigmi u područje istraživanja VRP-a koje su omogućile nove operacionalizacije uratka. Jedna od značajnijih promjena jest pojava zadatka kontinuirane procjene u istraživanjima pamćenja (Prinzmetal, Amiri, Allen i Edwards, 1998; Prinzmetal, Nwachuku, Bodanski, Blumenfeld i Shimizu, 1997). Zadatak kontinuirane procjene identičan je zadatku detekcije promjene, izuzev u fazi odgovaranja. U ovom zadatku u fazi odgovaranja signalizira se lokacija jednog od upamćenih objekata (npr. obojenog kvadrata), a zadatak sudionika je da na kontinuiranoj skali (npr. krugu boja) što preciznije označe vrijednost vidne karakteristike koju su pamtili. Uradak u takvom zadatku mjeri se kao pogreška dosjećanja (razlika između tražene vrijednosti i onoga što su se sudionici dosjetili), pri čemu pogreške sudionika nakon većeg broja sekvenci tipično izgledaju kao normalna distribucija s aritmetičkom sredinom $M = 0$ (nulta pogreška dosjećanja). Recipročna vrijednost standardne devijacije ili varijance takve distribucije koristi se kao mjera preciznosti dosjećanja.

Zhang i Luck (2008) proveli su istraživanje koristeći paradigmu kontinuirane procjene i pritom varirali broj elemenata koji su sudionici pamtili. Autori su predložili model utora prema kojem se distribucija pogrešaka dosjećanja može razložiti na dvije komponente: normalnu distribuciju koja opisuje točna dosjećanja i uniformnu distribuciju koja opisuje pogađanja (ovaj model se često naziva *normalna + uniformna distribucija*). Ideja iza ovakvog pristupa vrlo je jednostavna: ako je podražaj dobio svoj utor, dosjetit ćemo ga se relativno točno, uz vrlo malu pogrešku koja će se distribuirati prema normalnoj raspodjeli; ako podražaj nije dobio svoj utor, prilikom dosjećanja možemo jedino pogađati po slučaju što će rezultirati uniformnom distribucijom. Procjena pristajanja takvog modela mješovitih distribucija (McLachlan i Peel, 2000) rezultira procjenom tri parametra: proporcija točnih dosjećanja (p ; normalna distribucija), proporcija pogađanja ($1-p$; uniformna distribucija), i mnemonička preciznost (SD komponente točnih dosjećanja)¹. Svaki put kada ispitanik pamti broj vidnih elemenata koji je jednak ili manji

¹Važno je istaknuti razliku između preciznosti izračunate kao vrijednost recipročna SD pogrešaka dosjećanja,

kapacitetu pamćenja, točno se dosjećá zapamćenih objekata. Kada je broj elemenata koji se pamti veći od kapaciteta pamćenja, dio elemenata neće biti pohranjen u VRP - u fazi dosjećanja ispitanik će kod traženja nezapamćenih elemenata odgovarati po slučaju. Pretpostavka modela utora jest da će proporcija točnih dosjećanja biti stabilna dok god je broj elemenata koji se pamti jednak ili manji od kapaciteta. Kada broj elemenata bude veći od kapaciteta VRP-a, proporcija točnih dosjećanja će kontinuirano padati - ako sudionik u svakoj sekvenci pamti 3 od 6 prikazanih boja, na nekim sekvencama će ga se u fazi dosjećanja (po slučaju) tražiti da se dosjeti zapamćene boje, a nekad nezapamćene boje. Kombinacija takvih dosjećanja dovodi do pada proporcije točnih dosjećanja s porastom broja elemenata koji ostanu nezapamćeni.

Rezultati provedenog istraživanja pokazali su kako se, osim proporcije točnih dosjećanja, mijenja i standardna devijacija točnih dosjećanja. Konkretno, varijabilnost točnih dosjećanja rasla je do dužine nizova od tri podražaja, nakon čega ostaje stabilna. Prema tradicionalnim verzijama modela utora (tzv. *sve-ili-ništa*), osoba ili zapamti vidni objekt savršeno precizno ili ga ne zapamti uopće. Drugim riječima, mnemonička preciznost trebala bi biti konstantna i neovisna o broju elemenata koji se pamti. Kako bi objasnili nalaze istraživanja Zhang i Luck (2008) predložili su prošireni model utora, tzv. utori + uprosječivanje (engl. *slots + averaging*). Prema ovom modelu, utori se mogu dijeliti kada osoba pamti broj elemenata koji je manji od broja dostupnih utora. Kada ispitanik pamti samo jedan element, a raspolaže s tri utora ($K_{\max} = 3$), sva tri utora bit će dodijeljena jednom elementu što će dovesti do poboljšanja preciznosti s kojom je element zapamćen. Kada osoba pamti tri podražaja, svaki će dobiti jedan utora. S druge strane, kada osoba mora zapamtiti broj podražaja koji je veći od broja dostupnih utora, zapamtit će K_{\max} broj podražaja s određenom preciznosti, dok preostali podražaji neće biti zapamćeni te neće utjecati na mnemoničku preciznost podražaja koji su bili zapamćeni. Ovakav model koji pretpostavlja da su utori djeljivi na način sličan resursima kada je broj podražaja koji se pamti manji od K_{\max} pokazao je vrlo dobro pristajanje podacima.

Ovdje je važno naglasiti kako analiza same pogreške dosjećanja (npr. SD distribucije pogrešaka dosjećanja), bez dodatnog modeliranja, ne predstavlja test modela utora i ne omogućuje njegovu usporedbu s modelima resursa. Naime, modeli utora pretpostavljaju kako sirova pogreška dosjećanja raste s porastom broja podražaja koji se pamti. Kao što je već rečeno u kratkom opisu modela VRP-a na početku poglavlja, ova ista ideja temeljna je kod modela resursa. Ključ usporedbe ovih modela nalazi se u razlaganju ukupne pogreške na komponente dosjećanja. Pritom modeli utora pretpostavljaju kako promjene u pogrešci dosjećanja odražavaju: a) vrlo

te mnemoničke preciznosti, koja opisuje raspršenje isključivo u komponenti normalne distribucije točnih dosjećanja dobivenih procjenom modela mješovitih distribucija pogreškama dosjećanja. Prva vrijednost izračunata je na cijeloj distribuciji pogrešaka dosjećanja, dok je potonja izračunata na podacima kada se iz ukupnih dosjećanja odstrani dio rezultata koji se može pripisati pogađanjima, i u pravilu se prikazuje kao koncentracijski parametar Von Mises distribucije.

precizno pamćenje kada je broj podražaja $< K_{\max}$ uslijed uprosječivanja utora; b) kombinaciju točnih dosjećanja i slučajnog pogađanja kada je broj podražaja $\geq K_{\max}$. U sljedećem odjeljku dan je detaljniji opis modela resursa, no za sada recimo da ta skupina modela pokušava demonstrirati kako je podjela podražaja za zapamćene i nezapamćene pretjerano pojednostavljivanje.

Sve verzije modela utora, od tradicionalnih do modernih verzija, dijele pretpostavku kako je broj dostupnih utora strogo ograničen te da ljudi ne mogu povećavati broj utora pohranjujući vidne elemente nižom razinom preciznosti. Kako bi eksperimentalno provjerili ovu pretpostavku Zhang i Luck (2011) su kroz tri eksperimenta, koristeći različite manipulacije, pokušali stvoriti zahtjeve za pamćenjem visoke i pamćenjem niske preciznosti. Pretpostavka modela utora je kako se procjene broja utora u različitim eksperimentalnim situacijama neće razlikovati. Neovisno o tome jesu li autori utjecali na promjene u preciznost pamćenja promjenom vrste zadatka, davanjem povratnih informacija ili novčanim nagradama, niti u jednom od provedenih eksperimenata nisu pronašli razlike u procjenama broja utora između situacija niske i visoke preciznosti pamćenja. Autori su interpretirali ove rezultate kao snažan nalaz u prilog modela utora. Važno je istaknuti barem dva nedostatka ovog istraživanja. Prvo, autori nisu prikazali nikakav nalaz koji bi potvrdio da je njihova manipulacija preciznosti pamćenja stvarno bila uspješna. Štoviše, distribucije pogrešaka dosjećanja između dvije situacije kroz sva tri eksperimenta izgledaju gotovo identično (vidi Zhang i Luck (2011) 'Supplemental information'). Također, procjene preciznosti pamćenja na temelju modela mješovitih distribucija nisu pokazale uspješnu manipulaciju. Drugo, autori nisu testirali model koji dozvoljava pogrešna dosjećanja, tzv. pogreške zamjene (engl. *swap errors*) do kojih dolazi kada sudionik reproducira podražaj koji je zapamtio, ali koji nije bio tražen. Model koji su autori koristili (*normalna + uniformna distribucija*) takve odgovore tretira kao slučajna pogađanja i, iako su podražaji zapamćeni, smješta ih u uniformnu distribuciju procijenjenog modela. Stoga, procjena K_{\max} na temelju korištenog modela podcjenjuje broj zapamćenih objekata. Fougnie, Cormiea, Kanabar i Alvarez (2016) demonstrirali su kako se VRP može fleksibilno prilagoditi potrebama zadatka i prividno povećati kapacitet pamćenja uz odgovarajući trošak u preciznosti pojedinog utora. Kada su autori od sudionika uputom tražili da zapamte te se dosjete svih prikazanih podražaja, procijenjeni kapacitet bio je viši, a preciznost pojedinog dosjećanja niža u odnosu na klasičan zadatak VRP-a u kojem se od sudionika traži dosjećanje samo jednog podražaja.

Iz svega do sada navedenoga, jasna pretpostavka modela utora jest kako će se sudionici prilikom pamćenja npr. šest podražaja moći dosjetiti između tri i četiri podražaja (K_{\max}), dok će prilikom preostalih dosjećanja pogađati. Kako bi pokazali da je uradak sudionika u zadatku upravo takav, Adam, Vogel i Awh (2017) koristili su zadatak kontinuirane procjene te od sudionika tražili da samostalno odaberu redosljed dosjećanja i da se dosjete svih prikazanih podražaja. Pretpostavka autora bila je kako će se sudionici prvo dosjećati podražaja koje su

zapamtili, dok će one nezapamćene ostaviti za kraj. Pojednostavljeno, kod sudionika s $K_{\max} = 3$, distribucije dosjećanja kod pamćenja npr. šest podražaja trebale bi izgledati kao tri normalne (prva tri dosjećanja) i tri uniformne distribucije. U situaciji pamćenja šest podražaja, autori su na distribucijama pogrešaka dosjećanja usporedili pristajanje uniformne distribucije (samo pogađanje) te kombinacije normalne i uniformne distribucije (točno dosjećanje i pogađanje). Pretpostavili su kako će broj dosjećanja najbolje opisanih uniformnom distribucijom ukazivati na broj elemenata koji je ostao izvan pamćenja. Svaki trag pamćenja trebao bi biti identificiran normalnom komponentom modela i rezultirati u boljem pristajanju kombinacije normalne i uniformne distribucije. Rezultati su pokazali kako se između dva ili tri odgovora mogu najbolje opisati uniformnom distribucijom, odnosno pogađanjem. Nadalje, metakognitivne procjene o pogađanju, prikupljene nakon svakog dosjećanja, visoko su korelirale s procjenama pogađanja na temelju pogrešaka dosjećanja. Autori su zaključili kako rezultati ukazuju na jasno postojanje ograničenog kapaciteta najbolje opisanog postojanjem između tri do četiri utora. Ovdje je važno napomenuti kako Adam i sur. (2017) nisu uspoređivali pristajanje modela VRP-a podacima, te nisu prikazali nikakav nalaz koji bi potvrdio da su sudionici dostigli kapacitet VRP-a. Premda autori tvrde kako su našli konačan dokaz u prilog modela utora, a protiv modela resursa, usporedba modela *utori + uprosječivanje* s arbitrarno definiranim pogađanjem ne predstavlja osobito snažan nalaz u prilog modela utora. Važnije, ovo istraživanje ni na koji način ne eliminira modele resursa kao moguće objašnjenje nalaza.

Nekolicina istraživanja sugerirala je kako se bitan dio uratka u zadacima VRP-a može objasniti karakteristikama podražajnog materijala, te da je prije provjere pristajanja specifičnog modela VRP-a podacima, iz uratka potrebno izvojiti taj dio varijance. Na primjer, dobro utvrđen nalaz u istraživanjima percepcije i pamćenja jest onaj o superiornoj detekciji i preciznosti pamćenja kardinalnih (vertikalnih i horizontalnih) orijentacija (Girshick, Landy i Simoncelli, 2011; X.-X. Wei i Stocker, 2015), kao i onaj o različitoj preciznosti pamćenja prototipnih i neprototipnih boja (Bae, Olkkonen, Allred, Wilson i Flombaum, 2014; Hardman, Vergauwe i Ricker, 2017). Pratte, Park, Rademaker i Tong (2017) su pretpostavili kako u zadatku VRP-a takve varijacije mogu biti pogrešno interpretirane kao fleksibilna raspodjela resursa i na taj način zamagliti pravi odgovor na pitanje o prirodi pohrane u VRP. Kako bi provjerili tu hipotezu proveli su eksperiment u kojem su sudionicima prikazivali Gaborove podražaje različitih orijentacija manipulirajući pritom broj podražaja koji se pamtio. Test se sastojao u procjeni pristajanja dva modela opaženim pogreškama dosjećanja: *utori + uprosječivanje* (Zhang i Luck, 2008) i modela resursa, konkretno *varijabilne preciznosti* (van den Berg i sur., 2012). Kako bi provjerili hipotezu o specifičnom variranju pamćenja orijentacija, testirali su originalne verzije modela, a zatim i iste modele nakon što im je dodana trigonometrijska funkcija koja zahvaća variranje u dosjećanjima ovisno o kvaliteti podražaja koji se pamtio. Iako je model varijabilne preciznosti pokazao bolje pristajanje podacima, nakon dodavanja trigonometrijske funkcije, us-

poredba modela favorizirala je model utora. Autori su zaključili kako, nakon što se objasne specifična variranja u pamćenju ovisna o podražajima, priroda pohrane odgovara modelima utora. Nadalje, Pratte i sur. (2017) osmislili su model koji je kao osnovnu arhitekturu pretpostavljao diskretnu prirodu pamćenja motiviranu modelima utora, ali i dva dodatna izvora varijabiliteta - jedan vezan uz karakteristike podražaja i drugi, sasvim nespecifičan. Takav hibridni model utora pokazao je najbolje pristajanje podacima pokazujući kako se svo variranje u pamćenju ipak ne može objasniti podražajnim materijalom. Iako autori zaključuju kako priroda pohrane u osnovi prati pretpostavke modela utora, važno je napomenuti kako ovaj hibridni model nema niti jednu karakteristiku modela utora, osim njegovog imena.

Modeli utora predstavljaju prvu i dugo vremena dominantnu konceptualizaciju pohrane reprezentacija u VRP. Štoviše, od pojave koncepta kratkoročnog pamćenja (Atkinson i Shiffrin, 1968) do unazad deset godina, bili su jedini teorijski pogled na prirodu pohrane VRP. Pojavom modela resursa zagovornici ideje utora uložili su veliki napor kako bi dobili snažniju empirijsku potvrdu hipoteze utora. Taj napor uglavnom je rezultirao time da su današnje verzije modela utora bitno drugačije od ranih konceptualizacija. Iako objedinjeni pod imenom modeli utora, većina verzija ovih modela, poput modela *utori + uprosječivanje*, pretpostavljaju kako VRP može dijeliti utore dok god osoba pamti broj podražaja koji je manji od njenog K_{\max} . Drugim riječima, ovaj model pretpostavlja kako VRP funkcionira po principu resursa kad god se pamti manji broj podražaja, te kako postoji maksimalan broj podražaja koji osoba može zapamtiti. Na taj način, neki od modela utora predstavljaju hibrid između tradicionalnih modela utora i modela resursa. Nadalje, prve verzije modela utora pretpostavljale su da VRP funkcionira po principu "*sve-ili-ništa*" Luck i Vogel (1997). Ova pretpostavka predstavlja nerealistično očekivanje, naročito u kontekstu zadataka kontinuirane procjene. Noviji modeli utora pretpostavljaju kako je, jednom kada se pamti broj podražaja koji je jednak broju utora, preciznost pamćenja fiksna, ali ne i savršena. Konačno, tradicionalni modeli utora pretpostavljali su kako broj utora mora biti cijeli broj (Cowan, 2001; Rouder i sur., 2008). Današnji modeli barem implicitno pretpostavljaju kako je tijekom rješavanja zadataka broj dostupnih utora varijabilan (npr. zbog procesa pažnje) te dopuštaju da je procjena K_{\max} na temelju takvog variranja bude decimalni broj.

Prije opisivanja modela resursa, važno je istaknuti neke nedostatke modela utora. Bays (2018a) je nedavno demonstrirao kako modeli utora, konkretno *utori + uprosječivanje*, nude nekoliko načina za procjenu kapaciteta pamćenja, a koji rezultiraju međusobno različitim procjenama. Prema modelima utora, dva su načina za procjenu kapaciteta pamćenja. Prvi se sastoji od traženja maksimalne vrijednosti umnoška broja podražaja koji se pamti (N) i vjerojatnosti točnog dosjećanja uz taj N ($p_m(N)$). Drugi se sastoji u procjeni kapaciteta na temelju varijance pogrešaka dosjećanja uz nizove različite duljine. Podsjetimo se da bi ta varijanca trebala do-

seći plato i ostati stabilna jednom kada su svi utori popunjeni. Dva načina izračuna trebala bi rezultirati istim procjenama broja utora. Na temelju podataka iz osam prethodno objavljenih eksperimenata pronađena je ukupna korelacija $r = .25$ ($p = .025$). Nalaz da metoda izračuna kapaciteta VRP-a predviđa samo 6% varijance druge metode izračuna kapaciteta govori o nedosljednosti modela utora u kvantificiranju uratka VRP-a. Nedavno, Ma (2018) je istaknuo još jedan problem modela *utori + uprosječivanje* odnosno modela *normalna + uniformna* koji se često uzima kao test ove verzije modela utora. U tom radu, autor je generirao sintetske podatke na temelju modela varijabilne preciznosti i to tako da je proporciju pogađanja držao nultom. Drugim riječima, sva "dosjećanja" bila su točna dosjećanja, no razlikovala su se u preciznosti. Procjena pristajanja modela *normalna + uniformna* ovim podacima rezultirala je vrlo varijabilnom procjenom proporcije pogađanja, u nekim slučajevima i do 40%. Ova demonstracija pokazuje kako statistički model korišten za testiranje modela utora nije dovoljno osjetljiv na proces koji generira rezultate, u ovom slučaju, VRP varijabilne preciznosti.

1.2.2 Modeli resursa

Modeli resursa tvrde kako je pogled na VRP kao manji broj diskretnih stanja (npr. zapamćeno i nezapamćeno) pretjerano pojednostavljivanje. Rani modeli utora pretpostavljali su kako su podražaji u VRP-u pohranjeni kao diskretne jedinice i to savršeno precizno. Drugim riječima, modeli utora gledaju na pamćenje kao na binarno stanje - vidni objekt je kodiran ili nije. Pri tom, ne pretpostavlja se da bilo koji drugi faktor, poput distraktora, kriterija odlučivanja ili neuralnog šuma, može utjecati na bihevioralan odgovor (ponašanje). Na primjer, lažno pozitivan odgovor u zadatku detekcije promjene prema modelima utora može nastati samo kao posljedica pogađanja. Ova pretpostavka zanemaruje neke od elementarnih nalaza o funkcioniranju mozga, poput onog o stohastičkoj prirodi kodiranja informacija, tj. internalnom šumu kao sastavnoj komponenti svih kognitivnih procesa (Faisal, Selen i Wolpert, 2008). Upravo ta ideja jedna je od temeljnih u teoriji detekcije signala (TDS) (D. M. Green i Swets, 1966). Prema TDS-u, svaki vidni objekt u pamćenju neuralno je reprezentiran kao kontinuirana varijabla, a čiji je sastavni dio internalni šum koji se distribuira prema normalnoj raspodjeli. Takav pogled ujedno je i temeljna ideja modela resursa VRP. Rasprava modela resursa i modela utora predstavlja proširenje rasprave između TDS modela i modela praga (engl. *threshold models*) u područja psihofizike na područje pamćenja.

Rad Wilken i Ma (2004) predstavlja prvi eksplicitan test modela resursa VRP-a. Autori su u radu, koji se danas smatra klasičnim radom u području VRP-a, temeljito testirali pretpostavke modela utora i modela resursa, i to koristeći tradicionalan zadatak detekcije promjene, ali i, u to vrijeme novi, zadatak kontinuirane procjene. Prvi korak u testiranju modela resursa

bio je provjera ovog modela u klasičnom zadatku detekcije promjene. Koristeći različiti podražajni materijal (boje, orijentacije i spacijalnu frekvenciju) od sudionika su tražili da detektiraju promjenu između dva uzastopno prikazana niza, odijeljena fazom zadržavanja. Pritom, manipulirali su brojem podražaja koji se pamti (2, 4, 6 ili 8 boja i frekvencija te 2, 3, 4 ili 5 orijentacija) te su od sudionika tražili da izvijeste koliko su sigurni u svoj odgovor. Ovakav nacrt istraživanja omogućio je analizu osjetljivosti ispitanika te ROC krivulja (engl. *receiver operating characteristic curve*). Ukratko, ROC krivulja prikazuje rezultate uratka u zadatku detekcije promjene, konkretno, prikazuje odnos lažnih uzbuna i točnih detekcija uz različite razine sigurnosti sudionika u točnost vlastitih detekcija. I modeli resursa i modeli utora imaju vrlo jasne pretpostavke o uratku sudionika u takvom zadatku. Oba modela pretpostavljaju da će se osjetljivosti mijenjati s promjenom podražaja koji se pamti, i to kao posljedica pada točnih detekcija (H) i porasta broja lažnih uzbuna (FA) s porastom broja elemenata koji se pamti. Međutim, pretpostavke o izgledu ROC krivulja specificiraju prirodu promjene uratka s promjenom broja elemenata koji se pamti i pouzdanosti u detektiranu promjenu. Modeli utora pretpostavljaju kako se osjetljivost sudionika mijenja u skladu s modelima visokog praga (engl. *high-threshold model*) koje karakterizira linearan ROC pravac s nagibom jednakim ili manjim od 1 i odsječak koji iznosi $H = 1$ kad je broj pamćenih elemenata $N < K_{\max}$ (te $H = (K_{\max}/N + FA \times (1 - K_{\max}/N))$ kad je broj pamćenih elemenata $\geq K_{\max}$). Modeli resursa pretpostavljaju oblik ROC krivulja u skladu s TDS i d mjerom osjetljivosti. (Za detaljan pregled modela diskriminacije i impliciranih ROC krivulja te indeksa osjetljivosti vidi Swets (1986a) i Swets (1986b)).

Na deskriptivnoj razini, empirijske ROC krivulje više su odgovarale pretpostavkama modela resursa. Specifična hipoteza koju su autori željeli testirati bila je da do pada u uratku s porastom broja elemenata koji se pamti dolazi zbog porasta neuralnog šuma u vidnim reprezentacijama. Ako pojednostavimo neuralnu reprezentaciju vidnih podražaja i zamislimo da je svaki zapamćeni podražaj reprezentiran s jednim informacijskim kanalom opterećenim šumom - sudionik u zadatku detekcije promjene motri kanale i izvještava o promjeni kada signal u jednom kanalu pređe limen promjene. Uz porast broja kanala koji se motri, a uz fiksnu ukupnu količinu informacija koja se može prenijeti kanalima, raste vjerojatnost da se signal u nekom od kanala pogrešno protumači kao promjena. U terminima TDS, ova pretpostavka odražava porast varijance distribucije šuma s porastom broja elemenata koji se pamti. Usporedba pristajanja modela utora i modela resursa rezultirala je snažnim nalazima u prilog modela resursa. U prethodno opisanom istraživanju Rouder i sur. (2008) proveli su sličan test i pronašli podršku za modele utora. Važno je reći kako je u tom istraživanju pristajanje modela podacima utvrđeno na ROC krivuljama s po tri vrijednosti uz koje je vrlo teško detektirati različite oblike krivulja. Također, konačna verzija modela u tom radu imala je važan dodatan parametar, *propusti zbog nepažnje*, kojeg većina modela utora ne pretpostavlja i koji je, u model utora ali ne i model resursa, uveden tek nakon uvida u loše pristajanje originalnog modela utora podacima. Konačno, kako

bi direktnije izmjerili promjene u kvaliteti reprezentacija s porastom broja podražaja, Wilken i Ma (2004) su proveli gotovo identične eksperimente koristeći zadatak kontinuirane procjene. Rezultati su pokazali kako pogreška dosjećanja kontinuirano raste s porastom broja podražaja koji se pamti. Autori su kontinuirani porast pogreške dosjećanja s brojem upamćenih podražaja interpretirali kao dokaz u prilog modela resursa.

Bays i Husain (2008) ponudili su dodatan nalaz u prilog modelima resursa. Oni su u svom istraživanju pronašli pad u preciznosti dosjećanja s porastom broja zapamćenih elemenata, te pokazali kako se odnos dostupnih resursa i preciznosti reprezentacija može opisati jednostavnim potencijalnim odnosom, u skladu s istraživanjima koja su pokazala sličan potencijalni odnos preciznosti i broja neurona kojima je podražaj kodiran (Seung i Sompolinsky, 1993). Bays, Catalao i Husain (2009) na posebno domišljat način demonstrirali su važnost neuralnog šuma u zadacima VRP-a. Autori su pretpostavili kako uradak u zadatku ne ovisi samo o pamćenju kvalitete podražaja koje se sudionici trebaju dosjetiti (npr. boje) već i lokacije podražaja koja služi kao znak za dosjećanje. Kako su i kvaliteta koja se pamti i lokacije na kojima su podražaji bili prikazani kodirani nesavršeno, model VRP-a kod procjena uratka mora uzeti u obzir oba izvora pogrešaka. Konkretno, Bays i sur. (2009) su pretpostavili kako dio pogrešaka dosjećanja možemo objasniti time da sudionici kod dosjećanja reproduciraju zapamćenu boju (ili orijentaciju), ali ne onu koja se nalazila na lokaciji znaka za dosjećanje. Drugim riječima, sudionici zbog nepreciznog pamćenja zamjene lokacije podražaja i dosjete se podražaja kojeg su vidjeli, ali koji nije tražen. Model *utori + uprosječivanje* takve odgovore svrstava u slučajne pogotke te ih tretira kao znak da osoba nije zapamtila podražaj. Kako bi testirali tu pretpostavku, autori su osmislili model mješovitih distribucija koji pretpostavlja postojanje tri kategorije odgovora u zadatku dosjećanja: točna dosjećanja (komponenta normalne distribucije s $M = 0$), slučajni pogotci (uniformna distribucija) i pogreške zamjene (engl. *swap errors*; komponenta normalne distribucije centrirana na podražaje koji su prikazani, ali nisu traženi za dosjećanje). Prve dvije komponente ovog modela istovjetne su modelu *normalna + uniformna* korištenom kao potvrda modela *utori + uprosječivanje*. Posljednja komponenta, slično kao i slučajno pogađanje pokazuje pogreške dosjećanja, ali zajedno s prvom komponentom opisuje dosjećanje zapamćenih podražaja.

Rezultati su pokazali kako je značajnu količinu odgovora u zadatku kontinuirane procjene moguće opisati upravo distribucijom pogrešaka zamjena, pri čemu proporcija takvih odgovora raste s brojem podražaja koji se pamti, i to kao posljedica porasta uloge neuralnog šuma u pamćenju lokacija. Testiranje pristajanja modela *normalna + uniformna* rezultiralo je precjenjivanjem proporcije dosjećanja koji se mogu svrstati u slučajno pogađanje. Na primjer, kod pamćenja šest podražaja, model *normalna + uniformna* svrstava čak 48% odgovora kao slučajno pogađanje, dok u tro-komponentnom modelu samo 14% odgovora spada u uniformni dio

distribucije. Ovi rezultati pokazuju kako model *utori + uprosječivanje* u velikoj mjeri podcjenjuje količinu informacija koju sudionici pamte. Nadalje, modeli utora ne pretpostavljaju da sudionici pogađaju po slučaju dokle god je K_{\max} veći od broja podražaja koji se pamti. Rezultati ovog istraživanja pokazali su značajnu razliku u proporciji slučajnih pogodaka između pamćenja jednog i dva podražaja, što je broj podražaja bitno manji od obično procijenjenog kapaciteta VRP-a.

Schneegans i Bays (2016) dodatno su istražili pretpostavke modela resursa o pogreškama zamjene u zadatku VRP-a. Koristeći nizove s različitim brojem podražaja (boja odnosno oblika) autori su replicirali sada već klasičan nalaz o porastu pogreške dosjećanja s porastom broja podražaja koji se pamti. Kako je ovaj nalaz jednako konzistentan i s modelima resursa i s novijim modelima utora, autori su provjerili pristajanje obje vrste modela podacima. Prema modelima utora, uradak u ovakvom zadatku sastoji se od točnih dosjećanja za pamćenje između tri i četiri podražaja, odnosno točnih dosjećanja i slučajnog pogađanja kada sudionici pamte broj podražaja koji premašuje kapacitet VRP-a. Prema modelima resursa, svi podražaji su zapamćeni te ih možemo svrstati u dvije kategorije odgovora - točnih dosjećanja i pogrešaka zamjene. Usporedbom modela autori su pronašli kako najbolje pristajanje podacima pokazuje model mješovitih distribucija koji se sastoji od samo dvije komponente normalnih distribucija - točnih dosjećanja i pogrešaka zamjene. Prethodno opisani tro-komponentni model (točna dosjećanja, pogreške zamjene, te slučajno pogađanje) kao i dvo-komponentni model (*normalna + uniformna*) pokazali su lošije pristajanje podacima. Iako sudionici u istraživanjima VRP-a nesumnjivo ponekad odgovaraju po slučaju (pogađaju), ovo istraživanje pokazalo je kako ta vrsta odgovora ne objašnjava značajan dio uratka u zadatku kontinuirane procjene.

Važno pitanje na koje modeli resursa moraju odgovoriti jest kako VRP distribuira ukupnu količinu resursa između svih podražaja koji se pamte. Jedna mogućnost jest da se dostupni resursi dijele na jednake dijelove, ovisno o broju podražaja (Bays i Husain, 2008). Ako VRP dijeli dostupne resurse uvijek na jednake dijelove, svaki podražaj koji se pamti trebao bi dobiti jednaku količinu resursa, a samim time, sudionici nikada ne bi trebali pogađati prilikom dosjećanja. Alternativno, raspodjela resursa između podražaja može biti varijabilna (*model varijabilne preciznosti*, dalje u tekstu *VP model*; van den Berg i sur., 2012). Takva raspodjela pretpostavlja da određeni podražaj može dobiti veći dio ili čak većinu dostupnih resursa; to preostalim podražajima ostavlja manji ili čak neznatan dio resursa, čime bi se objasnilo naizgledno pogađanje u zadacima VRP. Važno je napomenuti kako je prema modelu varijabilne preciznosti jednaka raspodjela jedna od mogućnosti raspodjele resursa. van den Berg i sur. (2012) pretpostavili su kako je distribuiranje resursa stohastički proces koji u tipičnom zadatku varira između podražaja te od sekvence do sekvence, uz uvjet da se prosječna količina resursa po podražaju smanjuje kako broj podražaja koji se pamti raste. Ovaj model pretpostavlja kako se preciznost

pamćenja podražaja može opisati *gamma* distribucijom pri čemu parametri te distribucije ovise o ukupnom broju podražaja koji se pamti na način da je aritmetička sredina (prosječna preciznost) te distribucije manja uz pamćenje većeg broja podražaja. van den Berg i sur. (2012) testirali su ovaj model provedbom eksperimenta koristeći zadatke kontinuirane procjene i detekcije promjene. Osim modela VP, provjerili su pristajanje nekoliko modela podacima: klasični model utora, utori + uprosječivanje, model resursa s jednakom raspodjelom. Prikupljeni podaci pod obje paradigme, i kontinuirane procjene i detekcije promjene, favorizirali su model VP, čak i u usporedbi s modelom resursa koji pretpostavlja jednaku raspodjelu. Ovaj rad ponudio je dodatno i vrlo važno proširenje modela resursa.

Keshvari, van den Berg i Ma (2013) podvrgli su model varijabilne preciznosti dodatnom, strožem testu. Autori su koristeći zadatak detekcije promjene manipulirali brojem podražaja (jednostavnih orijentacija) koji se pamtio. Ključno, kontrolirali su veličinu promjene orijentacije podražaja koju su sudionici trebali detektirati, uz pretpostavku da će točnost detekcije rasti uz veći *signal-prema-šumu* omjer (engl. *signal-to-noise ratio*). Omjer reprezentacijskog signala i šuma raste kako se smanjuje broj podražaja koji sudionici pamte te uz veću promjenu koju je potrebno detektirati. Stariji modeli utora koji se temelje na modelima visokog praga pretpostavljaju da, kad god je podražaj zapamćen, osoba ima dovoljno informacija da detektira promjenu ako je do nje došlo. Drugim riječima, ne predviđaju nikakvu promjenu u detekciji s porastom veličine promjene koju treba detektirati. Istraživanje je reproduciralo već poznat nalaz o padu točnih detekcija i porastu lažnih uzbuna s povećanjem broja podražaja koji se pamtio. Nadalje, točnost detekcije promjene rasla je s veličinom promjene između podražaja, no taj porast bio je veći kod pamćenja manjeg broja podražaja. Autori su procijenili pristajanje većeg broja modela, uključujući tradicionalne i moderne verzije modela utora te dvije verzije modela resursa (modele jednake i varijabilne raspodjele). Model varijabilne preciznosti pokazao je najbolje pristajanje podacima, te je vrlo dobro reproducirao opažene proporcije detekcija i lažnih uzbuna, ali i promjene u točnim detekcijama s porastom veličine promjene. Važno, autori nisu pronašli nikakav nalaz u prilog fiksnom broju utora u VRP-u.

I druga istraživanja koristeći razne eksperimentalne nacрте i paradigme pronašla su dokaze u prilog modelima resursa, i specifično modelima varijabilne preciznosti (Fougnie, Suchow i Alvarez, 2012; Keshvari, van den Berg i Ma, 2012; Mazyar, van den Berg i Ma, 2012). Pretpostavka o varijabilnoj preciznosti kodiranja čini ovaj model neuralno plauzibilnim i usklađenim s velikim brojem istraživanja o prirodi kodiranja. Na općenitijoj razini, istraživanja su pokazala kako uzroci varijabilne obrade podražaja mogu biti različiti, uključujući karakteristike podražaja (Bae i sur., 2014; Girshick i sur., 2011; Pratte i sur., 2017), neodređenost podražaja (Keshvari i sur., 2012, 2013), kontekstualne efekte (Brady i Tenenbaum, 2013), fluktuacije pažnje (Cohen i Maunsell, 2009), relativnu važnost pamćenja pojedinog podražaja (Bays i Dowding,

2017) različito osipanje tijekom vremena (Fougny i sur., 2012) i stohastičku prirodu kodiranja (Sanger, 2003). S druge strane, model varijabilne preciznosti VRP-a ne specificira koji su sve izvori varijabilnosti prilikom kodiranja zbog čega ne predstavlja egzaktni model VRP-a.

Jedna od glavnih karakteristika VRP-a prema modelima resursa je fleksibilnost distribucije resursa. I dok se pretpostavka o varijabilnoj preciznosti odnosi na spontane varijacije u raspodjeli resursa, modeli resursa pretpostavljaju da se resursi VRP-a mogu dodjeljivati voljno. Na primjer, u istraživanjima u kojima se sudionicima nakon faze kodiranja podražaja istakne koji od podražaja ima najveću vjerojatnost dosjećanja, klasičan je nalaz da sudionici uspješno alociraju veću količinu resursa upravo tom podražaju što dovodi do veće preciznosti dosjećanja, ali uz trošak dosjećanja preostalih podražaja (Bays, Gorgoraptis, Wee, Marshall i Husain, 2011; Bays i Husain, 2008; Gorgoraptis, Catalao, Bays i Husain, 2011; Zokaei, Gorgoraptis, Bahrami, Bays i Husain, 2011). Detaljniji pregled ovih istraživanja dan je kasnije u tekstu (vidi *Prioritetnost i osvježavanje reprezentacija u pamćenju*).

Dodatan dokaz u prilog fleksibilnoj distribuciji resursa dolazi iz istraživanja koja su uspoređivala dosjećanja kod sekvencijalnog i simultanog prikazivanja podražaja. Gorgoraptis i sur. (2011) su sudionicima prikazivali nizove različitih dužina i to sekvencijalno ili simultano. S porastom broja podražaja koji se pamtio, prosječna preciznost dosjećanja kod sukcesivnog prikazanih podražaja imali je isti trend, ali je bila lošija nego u situaciji simultanog prikazivanja. Ovaj nalaz klasična istraživanja interpretiraju kao nefleksibilnost VRP-a da pohrani nove podražaje. Alternativno objašnjenje jest da sudionici u obje situacije prikaza jednako dobro pamte podražaje, no da kod sekvencijalnog prikaza lošije detektiraju kojeg se prikaza trebaju dosjetiti. Kako bi provjerili izvor opaženih razlika između dvije vrste prezentacija, provjerili su pristajanje tro-komponentnog modela mješovitih distribucija podacima. Analiza parametara tog modela pokazala je kako je preciznost točnih dosjećanja kontinuirano padala s porastom broja podražaja koji se pamtio, ali da se nije razlikovala između dvije situacije prikaza, rezultat koji modeli utora ne predviđaju. Ovaj rezultat pokazuje da opažene razlike u pogreškama dosjećanja između dvije situacije prikaza ne proizlaze iz lošijeg kodiranja podražaja. Drugim riječima, VRP fleksibilno dijeli resurse i kodira svaki podražaj. Odakle onda razlike u preciznosti između dvije situacije opažene na cjelovitim distribucijama dosjećanja? Najveća razlika između dvije situacije pronađena je u pogreškama zamjene, i to tako da je proporcija takvih dosjećanja rasla više u situaciji sekvencijalnog prikaza. Ukratko, opaženo veće raspršenje distribucija dosjećanja između dvije situacije mogu se objasniti pogreškama zamjene, a ne mnemoničkoj preciznosti zapamćenih podražaja.

Trenutno stanje područja istraživanja VRP-a obiluje nalazima u prilog modela resursa. Jedan izrazito uvjerljiv dokaz ponudili su van den Berg, Awh i Ma (2014). Oni su prikupili

podatke iz 10 objavljenih eksperimenata² i proveli svojevrstu meta-analizu. Autori su izdvojili nekoliko najvažnijih dimenzija pretpostavki po kojima se postojeći modeli razlikuju, uključujući pretpostavke o prirodi preciznosti pamćenja i postojanju fiksnog broja podražaja kojeg sudionici pamte. Kombinacijom svih postojećih pretpostavki autori su definirali 32 moguća modela, od kojih su samo neki objavljeni u literaturi, točnije njih 6. Na taj način, autori su uvažili i nepostojeće modele, ali koji barem hipotetski mogu nastati povezivanjem različitih pretpostavki iz različitih postojećih modela. Procjena pristajanja modela podacima pružila je snažan dokaz u prilog modelima resursa, pokazujući kako je preciznost pamćenja varijabilna te da se u prosjeku smanjuje s porastom broja elemenata koji se pamti.

Od prvih testova modela resursa do danas, veći je broj istraživanja validirao pretpostavke ovih modela koristeći mjere uratka osim pogrešaka dosjećanja i točnosti detekcije. Pearson, Raskevicius, Bays, Pertzov i Husain (2014) provjerili su pretpostavke modela resursa koristeći vremena latencije kod davanja odgovora kao mjeru uratka u zadatku VRP. Modeli resursa pretpostavljaju vezu između količine resursa dodijeljene podražaju i brzine kojom sudionici akumuliraju dokaze prilikom davanja odgovora (Reddi, Asrress i Carpenter, 2003). Konkretno, vremena latencije bi trebala biti povezana s kvalitetom reprezentacija na način da reprezentacije kojima je dodijeljeno manje resursa imaju duži proces akumulacije dokaza te sporije odgovaranje. Koristeći zadatak detekcije promjene, autori su potvrdili pretpostavke modela resursa pokazujući kako su vremena latencije uistinu bila duža kod pamćenja većeg broja podražaja. Osim toga, vremena latencije ovisila su o veličini promjene koju su sudionici morali detektirati, i to tako da su vremena latencije bila duža kada su sudionici morali detektirati manju promjena između dva prikaza, tj. kada su imali manje dokaza o promjeni. Ključno, jednostavan model akumulacije dokaza koji pretpostavlja kako vrijeme latencije ovisi o kvaliteti reprezentacije, uspješno je reproducirao podatke prikupljene u istraživanju.

Slično istraživanje koristeći zadatak kontinuirane procjene proveli su Schneegans i Bays (2016). Jedan od nedostataka upravo opisanog istraživanja Pearson i sur. (2014) jest taj što autori nisu mogli ispitati odnos vremena latencija i različitih vrsta odgovora (točnih i pogrešnih dosjećanja te pogodaka) u zadatku. Modeli resursa pretpostavljaju kako bi i u zadatku kontinuirane procjene vremena latencije trebala biti pozitivno povezana s pogreškom dosjećanja. Kako je raspodjela resursa kontinuirana, svako povećanje broja podražaja trebalo bi smanjiti kvalitetu reprezentacija u VRP-u i tako usporiti akumulaciju dokaza kod davanja odgovora. Prema modelima utora, vremena latencije trebala bi doseći plato jednom kada svi utori budu popunjeni. Konkretno, nakon što svaki utror bude popunjen, daljnje povećanje broja elemenata koji se pamti ne bi trebao utjecati na dosjećanje podražaja koji su dobili utror, već se mijenja samo broj podražaja izvan pamćenja. Drugim riječima, dosjećanje zapamćenih podražaja prema mo-

²Dva rada iz kojih su podaci korišteni naknadno su povučeni

delu utora jednako je pamti li sudionik 4 ili 8 podražaja. Schneegans i Bays (2016) su pristupom mješovitih distribucija izdvojili samo one sekvence na kojima je odgovor spadao u komponentu distribucije točnih dosjećanja. Na taj način analizirana su samo vremena latencije dosjećanja onih podražaja koji su prema modelima utora dobili utor. Rezultati su pokazali kontinuirani porast vremena latencije za nizove svih duljina (1, 2, 4 i 8 podražaja). Dodatno, autori su pronašli pozitivnu korelaciju vremena latencije i pogreške dosjećanja i to unutar nizova pojedine duljine. Ovo istraživanje demonstriralo je nalaze o odnosu vremena latencije i kvalitete reprezentacija u VRP-u kakve pretpostavljaju modeli resursa, ali koji su istovremeno nekonzistentni s pretpostavkama modela utora.

Na tragu istraživanja o odnosu preciznosti pamćenja i vremenu akumulacije postavlja se i hipoteza o povezanosti preciznosti pamćenja i metakognicije o kvaliteti pamćenja (Brady, Konkle, Gill, Oliva i Alvarez, 2013; Gold i Shadlen, 2007). Konkretno, vrijeme potrebno da se pristupi nekoj reprezentaciji moglo bi poslužiti kao osnova za procjenu kvalitete reprezentacija u VRP. Kvalitetne reprezentacije (one kojima je pridana veća količina resursa) zahtijevaju manje vremena da bi im se pristupilo, a upravo to vrijeme je potencijalna osnova koju sudionici mogu koristiti za metakognitivnu procjenu kvalitete pamćenja. Prethodna istraživanja pronašla su značajnu povezanost uratka u zadacima VRP-a i samoprocjena kvalitete uratka (Bays, 2016b; Bona, Cattaneo, Vecchi, Soto i Silvanto, 2013; Bona i Silvanto, 2014; Rademaker, Tredway i Tong, 2012). Suchow, Fougne i Alvarez (2017) su proveli istraživanje u kojima su od sudionika tražili da se od većeg broja zapamćenih podražaja dosjete onog kojeg su zapamtili najbolje. Nekoliko dana nakon provedbe tog eksperimenta, pozvali su iste sudionike i rekli im kako će rješavati sličan zadatak no da će sada računalo po slučaju odabrati podražaje za dosjećanje. Autori su sudionicima zapravo prikazali identične sekvence i tražili od njih da se dosjete istih onih podražaja koje su sudionici nekoliko dana ranije svojevolumno odabrali. Preciznost dosjećanja istih podražaja (u istoj konstelaciji i kontekstu) bila je bolja kada su sudionici sami odabirali koji podražaj su najbolje zapamtili. U sljedeća dva eksperimenta, autori su od sudionika tražili da se dosjete ili najboljeg ili najlošije zapamćenog podražaja, odnosno, dosjećanje je bilo uvjetovano metakognitivnom procjenom kvalitete zapamćenog materijala. Rezultati su pokazali kako sudionici imaju vrlo dobre metakognitivne procjene o reprezentacijama u VRP-u. Štoviše, sudionici su vrlo dobro procjenjivali i promjene u kvaliteti reprezentacija do kojih je došlo uslijed metakognitivnih procjena. Ovaj nalaz pokazuje kako su sudionici imali pristup trenutačnom stupnju kvalitete reprezentacija koji se mijenja kao posljedica razmišljanja o tome kakva je kvaliteta pojedinog podražaja.

van den Berg, Yoo i Ma (2017) dodatno su razradili pretpostavku o kvaliteti reprezentacija VRP-a kao temelju metakognitivnih procjena uratka u zadacima VRP. Autori su predložili model koji pretpostavlja relativno jednostavan odnos preciznosti pamćenja i samoprocjena uratka.

Konkretno, model pretpostavlja da samoprocjene uratka prate preciznost pamćenja preko Fechnerovog zakona, odnosno da su logaritamska funkcija preciznosti pamćenja, u skladu s pretpostavkama o logaritamskom kodiranju odnosa podražaja i osjeta u mozgu (Gold i Shadlen, 2001; Juslin, Nilsson, Winman i Lindskog, 2011; Sun, Wang, Goyal i Varshney, 2012). Fechnerov zakon opisuje kakav je odnos intenzitet fizikalnog podražaja i njegovog psihološkog doživljaja, dok model van den Berga i sur. (2017) pretpostavlja kako metakognitivne procjene proizlaze pomoću istog odnosa iz količine resursa koju VRP dodijeli podražaju. Ovaj model pokazao je odlično pristajanje bivarijantnim distribucijama pogrešaka dosjećanja i samoprocjena uratka prikupljenih zadatkom kontinuirane procjene.

Modeli resursa u svojoj kratkoj povijesti postojanja bitno su izmijenili pogled na VRP. Uvođenjem novih eksperimentalnih paradigmi, analiza podataka, te validacijom koncepta resursa bihevioralnim i neuralnim mjerama, revidirali su nalaze koje je tijekom pedesetak godina generirala jedna hipoteza o prirodi pohrane. Jednako važno, istraživanja potaknuta modelima resursa istaknula su nekonzistentnost kao i neke nelogičnosti većine pretpostavki modela utora. Modeli resursa i modeli utora predstavljaju dominantne, ali ne jedine modele prirode VRP. Ipak, većina preostalih značajnih modela VRP-a (Alvarez i Cavanagh, 2004; Awh, Barton i Vogel, 2007; Donkin, Kary, Tahir i Taylor, 2016; Hardman i sur., 2017; Nassar, Helmers i Frank, 2018; Nosofsky i Donkin, 2016; Oberauer i Lin, 2017; Schurgin, Wixted i Brady, 2018; Xu i Chun, 2006) može se pojednostaviti i svesti pod jednu od dvije široke hipoteze o prirodi pohrane.

1.2.3 Neuralna osnova vidnog radnog pamćenja

Neuralna istraživanja VRP-a najviše truda uložila su u pokušaj odgonetavanja lokacije pohrane VRP-a. Kao rezultat toga nastale su dvije široke hipoteze o lokaciji pohrane reprezentacija. Senzorna hipoteza pretpostavlja da se podražaji primarno pohranjuju u senzorna vidna područja, a kao glavni dokazi u prilog ovoj hipotezi služe istraživanja vidnih područja (V1–V4) čiji obrasci aktivacije omogućavaju uspješno dekodiranje informacija o zapamćenim podražajima (Emrich, Riggall, LaRocque i Postle, 2013; S. A. Harrison i Tong, 2009; Serences, Ester, Vogel i Awh, 2009). Druga hipoteza usmjerava se na područja u kojima aktivnost raste s količinom informacija koju osoba motri u zadatku (Drew i Vogel, 2008), pridaje pažnju (Mitchell i Cusack, 2008) ili pohranjuje (Todd i Marois, 2004; Xu i Chun, 2006) (za detaljan pregled istraživanja vezanih uz ove hipoteze vidi Gayet, Paffen i Van der Stigchel, 2017; Scimeca, Kiyonaga i D'Esposito, 2018; Xu, 2017, 2018).

Istraživanja koja su koristila funkcionalnu magnetsku rezonancu (fMR) identificirala su prefrontalne i posteriorne parijetalne dijelove kore mozga kao potencijalnu neuralnu osnovu VRP-a, demonstrirajući povišene BOLD (engl. *blood-oxygen level-dependent*) signale tijekom

zadatka VRP-a (Todd i Marois, 2004; Xu i Chun, 2006). Xu i Chun (2006) od sudionika su tražile da zapamte prikaze s različitim brojem podražaja te nakon kratkog perioda zadržavanja detektiraju razlikuje li se testni prikaz od zapamćenog. Snimajući neuralne signale fMR autori su identificirali inferiorni intraparijetalni sulcus (inferiorni IPS) kao primarni spremnik VRP-a, i to na temelju promjena u aktivnosti koje su blisko pratile promjene u broju podražaja koji se pamti, s platoon aktivnosti oko četiri zapamćena objekta. Ovaj nalaz je u skladu s dotadašnjim poimanjem pohrane u VRP-u, ali prije svega je i intuitivan - teži zadatak prati veći neuralni angažman. Nadalje, superiorni IPS i lateralno okcipitalni korteks (LOC) pokazali su promjene u aktivnosti osjetljive na kompleksnost podražaja s većom aktivacijom kada su sudionici pamtili kompleksnije vidne podražaje. Na temelju ovih nalaza autori su zaključili kako je VRP ograničeno kapacitetom ali i kompleksnosti podražaja koji se pamte, s relativno jasnim neuralnim područjima u pozadini obje odrednice.

Nedavna istraživanja dovela su u pitanje ove zaključke koristeći napredne analitičke strategije obrade fMR signala, poput multivarijatne obrade traga (MVPA; eng. *multivariate pattern analysis*). MVPA (Haxby, 2001) je skupni naziv za analitičke metode strojnog učenja koje na temelju obrazaca aktivnosti u određenim područjima mozga pokušavaju predvidjeti, tj. "dekodirati", karakteristike podražaja (MVPA je danas vjerojatno najraširenija analiza u neuralnim istraživanjima VRP-a, ali vidi nedostatke ove metode Dubois, de Berker i Tsao, 2015; Ritchie, Kaplan i Klein, 2017). S. A. Harrison i Tong (2009) i Serences i sur. (2009) koristeći MVPA na fMR podacima prikupljenima tijekom rješavanja zadatka VRP-a, uspješno su dekodirali karakteristike podražajnog materijala kojeg su sudionici pamtili na temelju obrazaca aktivnosti senzornih vidnih područja, uključujući V1. Posebno važan nalaz ovog istraživanja bio je da senzorna vidna područja nisu pokazivala povišene razine aktivnosti tijekom faze zadržavanja u zadatku VRP-a. Riggall i Postle (2012) demonstrirali su kako je informacije o zapamćenim orijentacijama podražaja moguće dekodirati iz senzornih vidnih područja, ali ne i iz intraparijetalnih i prefrontalnih dijelova kore mozga koje pokazuju povišene razine aktivnosti tijekom faze zadržavanja u zadatku VRP-a, nalaz koji se tipično interpretirao kao indikator lokacije pohrane podražaja VRP-a. Važno proširenje ovog nalaza ponudili su Emrich i sur. (2013), pokazavši povezanost točnosti dekodiranja MVPA i bihevioralne mjere preciznosti dosjećanja. I druga istraživanja pokazala su uspješno dekodiranje informacija na temelju neuralnih signala iz vidnih područja (Albers, Kok, Toni, Dijkerman i de Lange, 2013; E. Ester, Sprague i Serences, 2015; E. F. Ester, Anderson, Serences i Awh, 2013; E. F. Ester, Serences i Awh, 2009; Lee, Kravitz i Baker, 2013; Lorenc, Sreenivasan, Nee, Vandembroucke i D'Esposito, 2018; Rademaker, Chunharas i Serences, 2018; Sprague, Ester i Serences, 2014; Xing, Ledgeway, McGraw i Schluppeck, 2013; Yu i Shim, 2017). Korištenjem naprednih statističkih metoda za analizu obrazaca neuralne aktivnosti pažnja je pomaknuta s područja čija aktivnost varira s količinom informacija koja se pamti na područja koja sadrže informacije o zadatku kojeg osoba obavlja.

Važno je napomenuti kako ovi nalazi ne govore kako parijetalni i prefrontalni dijelovi kore nisu nikada angažirani prilikom pohrane podražaja. Čini se kako je ključna odrednica toga vrsta podražaja koja se pamti. Specifično, hoće li neko područje pohraniti informacije tijekom zadatka VRP-a ovisi o tome je li to područje mozga aktivno kod percepcije ili druge vrste procesiranja konkretnog tipa informacija. Kada zadatak VRP-a ne zahtijeva samo pamćenje jednostavnih orijentacija, već apstraktnih vidnih podražaja, lica ili kuća, osim senzornih vidnih područja, parijetalni i temporalni dijelovi kore također nose informacije o podražaju (Christophel i Haynes, 2014; Christophel, Hebart i Haynes, 2012; Nelissen, Stokes, Nobre i Rushworth, 2013). Jerde, Merriam, Riggall, Hedges i Curtis (2012) su pokazali kako MVPA klasifikator treniran na jednoj od tri eksperimentalne situacije - usmjeravanje pažnje, planiranje sakade i zadatku VRP-a - može dekodirati vidne informacije u preostale dvije situacije. Ovi rezultati mogu se interpretirati kao nalaz o isprepletenosti različitih kognitivnih procesa poput pažnje, planiranja i pamćenja. Alternativno, moguće je da jedan od procesa, prisutan u svim preostala zadacima, objašnjava ove nalaze. Pritom, pažnja se u literaturi smatra najsveobuhvatnijim procesom.

Nekoliko istraživanja pokušalo je eksperimentalno razdvojiti procese pažnje i VRP-a. Jedan posebno koristan pristup razdvajanja ovih procesa jest dekodiranje informacija pomoću MVPA iz neuralnih signala opaženih u jednostavnim eksperimentalnim zadacima (LaRocque, Lewis-Peacock, Drysdale, Oberauer i Postle, 2013; LaRocque, Riggall, Emrich i Postle, 2017; Lewis-Peacock, Drysdale, Oberauer i Postle, 2012). U ovim studijama, zadatak sudionika bio je da zapamte dva podražaja nakon čega je jedan od njih označen kao relevantan za zadatak dosjećanja i time doveden u fokus pažnje (usmjeravanja pažnje unatrag, engl. *retro-cueing*). Ključno, sudionici nisu smjeli zaboraviti drugi podražaj jer je nakon prvog zadatka dosjećanja uslijedio drugi zadatak dosjećanja u kojem je od sudionika traženo da se ponovno dosjete prvog ili drugog podražaja. Na taj način, tijekom zadatka prvog dosjećanja, drugi podražaj je bio u VRP-u, ali izvan fokusa pažnje. MVPA prikupljenih fMR i EEG podataka nije pokazala uspješno dekodiranje podražaja dok se on nalazio izvan fokusa pažnje, iako je dekodiranje bilo uspješno jednom kada je taj podražaj vraćen u fokus. Ova istraživanja govore kako opaženi neuralni signali u studijama VRP-a možda odražavaju fokus pažnje, a ne pohranu u VRP-u. Nadalje, ovi rezultati impliciraju i kako su reprezentacije VRP-a pohranjene u tzv. neuralno 'tihim područjima', tj. onima koja ne pokazuju povišen angažman tijekom zadatka VRP-a.

Osim istraživanja specifičnih neuralnih područja, znatna pažnja poklonjena je istraživanjima distribuiranih neuralnih signala koji nisu nužno vezani uz isključivo senzorna ili prefrontalna područja. Prilikom istraživanja neuralne osnove VRP-a, modeli utora usmjeravali su se na kontralateralnu odgođenu aktivnost (engl. *contralateral delay activity*, CDA), evocirani potencijal vezan uz prezentaciju podražaja, koji predstavlja razliku kontralateralne i ispilate-

ralne aktivnosti mozga (Luria, Balaban, Awh i Vogel, 2016). U fazi zadržavanja u zadacima VRP-a ovaj signal pokazuje porast amplitude s povećanjem broja podražaja koji se pamti, te plato nakon dostizanja kapaciteta VRP (Adam, Robison i Vogel, 2018; Vogel i Machizawa, 2004; Vogel, McCollough i Machizawa, 2005). Ovaj nalaz u skladu je s hipotezom starijih modela utora koja pretpostavlja kako pamćenje svakog sljedećeg podražaja angažira novi utor sve dok se ne 'potroše' svi utori. Noviji modeli utora (Zhang i Luck, 2008) pretpostavljaju da se višak utora distribuira na sve podražaje što implicira kako CDA, ali i niti jedan drugi signal koji varira s brojem podražaja, nije neuralni marker kodiranja informacija u VRP. Unatoč tome, pristaše modela utora i danas zagovaraju kako je CDA indikator pohrane podražaja u VRP (npr. Adam i sur., 2018). U skladu s prethodnim fMR istraživanjima lokalizacije VRP-a (Todd i Marois, 2004; Xu i Chun, 2006), nekoliko istraživanja predložilo je kako je izvor ovog signala u parijetalnim dijelovima mozga (Becke, Müller, Vellage, Schoenfeld i Hopf, 2015; Robitaille, Grimault i Jolicœur, 2009). Nadalje, pokazano je da plato u amplitudi CDA korelira s individualnim razlikama u kapacitetu VRP-a. Luria i sur. (2016) proveli su meta-analizu 11 studija koje su mjerile povezanost CDA i kapaciteta VRP-a i pronašli ukupan efekt povezanosti $r = .596$, što sugerira kako je CDA izgledna neuralna osnova VRP-a.

Važno je napomenuti kako ova istraživanja počivaju na pretpostavci da CDA amplituda doista dostiže plato. Alternativna interpretacija opaženih promjena CDA jest da se ona ne mijenja prema bilinearnoj već nekoj drugoj funkciji. Jedna alternativa je saturacijski model prema kojem signal raste u eksponencijalnoj funkciji na način da svaki sljedeći porast u broju podražaja koji se pamti rezultira manjim porastom u neuralnom signalu. Bays (2018b) je nedavno testirao podatke klasičnih istraživanja (Todd i Marois, 2004; Vogel i Machizawa, 2004; Xu i Chun, 2006) koja su naizgledni plato neuralne aktivnosti tumačile kao znak dostignutog kapaciteta VRP-a. Usporedbom saturacijskog i modela platoa, Bays (2018b) je pokazao kako podatke bolje opisuje saturacijski model prema kojem analizirani signali asimptotski rastu, te na taj način opovrgnuo tvrdnje o prividnom platou amplitude neuralnih signala kao dokazu ograničenog broja utora.

I nalazi drugih istraživanja potaknula su sumnju u CDA kao neuralni marker VRP-a. Konkretno, čini se kako je CDA signal prisutan u većem broju vidnih zadataka, poput zadatka praćenja objekata (Drew i Vogel, 2008) te perceptivnim zadacima detekcije u kojem su podražaji prikazani cijelo vrijeme (Tsubomi i sur., 2013). Kundu, Sutterer, Emrich i Postle (2013) su pokazali kako trening VRP-a smanjuje CDA tijekom zadatka vidne pretrage i zadatka VRP-a, usprkos tome što je uradak na bihevioralnoj razini očekivano nakon treninga bio bolji. Ako je CDA doista neuralni marker VRP-a, amplituda tog signala također bi trebala rasti uz trening VRP-a. Konačno, CDA se najviše povezuje s oscilacijom alfa valova koje odražavaju široki kognitivni angažman, a ne specifičan zadatak poput pohrane u VRP (van Dijk, van der Werf,

Mazaheri, Medendorp i Jensen, 2010).

Dvije prethodno predstavljene hipoteze, o angažmanu isključivo senzornih ili isključivo prefrontalnih i parijetalnih dijelova kore, prilikom pohrane podražaja u VRP predstavljaju pojednostavljene. Neuralna (Bettencourt i Xu, 2016) i bihevioralna (W. J. Harrison i Bays, 2018) istraživanja odbacila su senzorna područja kao primarno mjesto pohrane VRP-a; no isto vrijedi i za parijetalna i prefrontalna područja (Lewis-Peacock i sur., 2012). Nadalje, istraživanjima specifičnih neuralnih signala poput CDA upućeni su broji prigovori (B. R. Postle, 2015) i čini se kako ne postoji jedinstveni neuralni signal koji odražava pohranu u VRP. Odgovor o točnoj lokalizaciji procesa pohrane je vjerojatno mnogo složeniji. Lokalizacija neuralnih markera VRP-a ovisi o vrsti podražaja i zadatku, te je najizgledniji odgovor kako VRP angažira širu mrežu neuralnih područja koja zajednički obavljaju zadatak ovisno o specifičnim zahtjevima (Christophel, Klink, Spitzer, Roelfsema i Haynes, 2017). Jedna utjecajna hipoteza pretpostavlja interakciju senzornih područja, prefrontalnog (PFC) i posteriornog parijetalnog korteksa (PPC) prilikom obrade podražaja u VRP-u (Xu, 2017). Tijekom kodiranja podražaja, PPC i senzorna područja pod utjecajem su kontrole PFC kako bi se osiguralo kodiranje podražaja (senzorna područja) i transfer tih reprezentacija za pohranu (PPC i PFC). Tijekom faze zadržavanja, PFC komunicira sa senzornim područjima kontrolom *odozgo-prema-dolje* kako bi se facilitirala nadolazeća usporedba pohranjenog i testnog podražaja za fazu dosjećanja. Iako i u fazi dosjećanja (usporedbe u zadatku detekcije) dolazi do ponovne aktivacije senzornih područja (Xu i Chun, 2006), reprezentacije u VRP-u niti u toj fazi ne počivaju samo na aktivnosti senzornih područja, već i PFC i PPC. Ukratko, funkcija senzornih područja je prvenstveno kodiranje, PPC pohrana, a PFC kontrola i pohrana.

1.2.4 Neuralni modeli vidnog radnog pamćenja

Područje istraživanja VRP-a predstavlja interdisciplinarno područje u kojem je, osim bihevioralnih i neuralnih istraživanja, računarski pristup pružio brojne važne uvide. I dok su neuralna istraživanja većinom fokusirana na traženje neuralnih markera VRP-a, neuralno računarski pristup usmjeren je na traženje biološki plauzibilnih mehanizama kojim VRP pohranjuje informacije. Jedan posebno uspješan model neuralne osnove VRP-a predložio je Bays (2014, 2015). Njegov model počiva na nalazu o populacijskom kodiranju kao temeljnom mehanizmu pohrane senzornih reprezentacija (Pouget, Dayan i Zemel, 2000; Zemel, Dayan i Pouget, 1998). U ovom modelu, svaki podražaj kodiran je populacijom ugođenih neurona čija aktivnost ovisi o kvalitetu podražaja (npr. naj snažnija aktivnost kod specifične orijentacije), pri čemu je aktivnost svakog neurona određena Poissonovim procesom (Faisal i sur., 2008). Baysov model pretpostavlja kako je neuralna osnova resursa aktivnost populacije, odnosno akcijski potencijali. To

znači da je podražaju kodiranom većim brojem akcijskih potencijala dodijeljeno više resursa. Ukupna aktivnost populacije neurona konstantna je neovisno o broju podražaja koji se pamti, u skladu s mehanizmom globalne neuralne normalizacije (Carandini i Heeger, 2011). Na taj način, ukupna količina akcijskih potencijala odražava ukupnu količinu resursa. Povećanjem broja podražaja koji se pamti ukupna aktivnost populacije (resursi) dijeli se između svih podražaja što dovodi do manjeg omjera signala i šuma. Dosjećanje je u ovom modelu određeno prema kriteriju maksimalne vjerodostojnosti (engl. *maximum likelihood*). Kako je šum sastavni dio neuralne aktivnosti, rekonstruirane procjene pokazuju varijabilnost oko prave vrijednosti. Pri tom, što je manja količina aktivnosti (resursa) dodijeljena podražaju, veća je uloga neuralnog šuma i veća je varijabilnost rekonstruiranih procjena.

Baysov neuralni model ekstenzija je njegovih prethodnih deskriptivnih modela (Bays i sur., 2009; Bays i Husain, 2008) koji su pretpostavljali jednaku raspodjelu resursa i time implicirali jednaku preciznost dosjećanja. Neuralni model pretpostavlja jednaku raspodjelu resursa, ali ne i jednaku preciznost dosjećanja. Ključna karakteristika ovog modela je stohastička priroda aktivnosti neurona što znači da će svaki podražaj biti kodiran brojem akcijskih potencijala određenim Poissonovim procesom. Ukratko, ovaj model pretpostavlja kako varijabilitet dosjećanja opažen u bihevioralnim studijama možemo objasniti neuralnim šumom, a njegova uloga je to izražena što je manji omjer *signal-naprama-šum*. Ovaj model uspješno zahvaća potencijalski odnos broja podražaja koji se pamti i preciznosti (Bays i Husain, 2008) te tipično opažena odstupanja distribucija dosjećanja od normalne distribucije (Bays, 2014).

Iako originalni model pretpostavlja uniformnu raspodjelu neurona kroz cijeli raspon vrijednosti koji se kodira (npr. sve moguće orijentacije podražaja kodirane su jednakim brojem neurona), nedavna modifikacija modela (Taylor i Bays, 2018) u skladu s hipotezom efikasnog kodiranja (Barlow, 1961) uspješno je zahvatila nalaz o preciznijem dosjećanju kardinalnih osi prilikom pamćenja orijentacija u zadatku VRP-a. U tom istraživanju Taylor i Bays (2018) pokazali su bolje pristajanje modela populacijskog kodiranja od prethodno opisanog modela utora proširenog za trigonometrijsku funkciju koja zahvaća, ali ne opisuje, promjene u preciznosti ovisno o karakteristikama podražaja Pratte i sur. (2017). Baysov neuralni model doživio je još nekoliko proširenja u cilju objašnjavanja uratka u tipičnim zadacima VRP-a. Schneegans i Bays (2017a) ponudili su neuralni model povezivanja svojstava (engl. *feature binding*) u jedinstvenu reprezentaciju objekta (npr. orijentacija i boja). U tom radu, autori su testirali dvije hipoteze o povezivanju svojstava: direktnom povezivanju i povezivanju preko dijeljenog prostornog položaja. Ukratko, podaci su favorizirali potonji model. Ključno, neuralni model uspješno je predvidio pogreške dosjećanja u bihevioralnom zadatku u kojem su sudionici pamtali podražaje sastavljene od dva svojstva (orijentacije i boje) razmještene na razne lokacije po ekranu, a dosjećali se jednog svojstva (npr. orijentacije) i prostornog položaja dok im je kao znak za

dosjećanje služilo drugo zapamćene svojstvo (npr. boja). Autori su pretpostavili kako će se pogreške povezivanja odraziti u pogreškama zamjene, te da će te pogreške (npr. pogrešno dosjećanje boje) biti to češće što je znak za dosjećanje sličniji (npr. po orijentaciji) nekom drugom zapamćenom podražaju. Neuralni model objašnjava ove pogreške kao posljedicu neuralnog šuma u populaciji koja kodira podražaj, u skladu s temeljnom idejom modela resursa. Model slične arhitekture koji su nedavno predložili Oberauer i Lin (2017) također je pokazao vrlo dobro pristajanje bihevioralno prikupljenim podacima.

Bays i Taylor (2018) nedavno su provjerili pristajanje originalnog modela populacijskog kodiranja podacima prikupljenima u osam objavljenih istraživanja zadatkom usmjeravanja pažnje unatrag (engl. *retro-cueing*). Tipičan nalaz ovih istraživanja jest preciznije dosjećanje podražaja koji je nakon kodiranja doveden u fokus pažnje u usporedbi s podražajem koji nije doveden u fokus pažnje (za pregled istraživanja vidi Souza i Oberauer, 2016). Procjena pristajanja modela podacima pokazala je kako signaliziranje unatrag utječe na procijenjeni parametar aktivnosti populacije neurona (količinu resursa), ali ne i na ostale parametre modela (funkcije ugođenosti neurona). Iako je točan mehanizam kojim signaliziranje djeluje nepoznat, ovi rezultati su u skladu s podacima bihevioralnih istraživanja koji pokazuju bolje dosjećanje (više dodijeljenih resursa) podražaju koji je doveden u fokus pažnje (signaliziran).

Konačno, Schneegans i Bays (2018) nedavno su pokazali kako model populacijskog kodiranja može uspješno objasniti pad preciznosti VRP-a s produženjem vremena pamćenja. Tipično, ovaj nalaz interpretira se kao osipanje VRP-a; neuralni korelat takvog osipanja trebao bi biti smanjenje aktivnosti populacije neurona u kojoj su podražaji pohranjeni. Alternativno, lošiji uradak može biti posljedica 'klizanja' (engl. *drift*) prvotno kodiranih vrijednosti u prostoru svih mogućih vrijednosti, bez smanjenja populacijske aktivnosti tijekom vremena. Autori su pokazali tipičan pad preciznosti s porastom broja podražaja koji se pamti i produljenjem vremena pamćenja. S druge strane, vremena odgovora produljivala su se samo s porastom podražaja koji se pamtio, ali ne i s produžetkom vremena pamćenja. Drugim riječima, proces dosjećanja ovisio je samo o broju podražaja koji se pamtio, u skladu sa sporijim akumuliranjem dokaza; produženje vremena retencije nije dovelo do tog efekta, odnosno sudionici su pronalazili odgovor, ne nužno precizan, jednako brzo neovisno o tome koliko dugo su ga pamtali. Ovi podaci uspješno su zahvaćeni modelom populacijskog kodiranja koji ne pretpostavlja osipanje, već u kojem reprezentacije 'kližu' kroz prostor mogućih vrijednosti podražaja tijekom vremena.

Kako je već rečeno, velik broj neuralnih istraživanja usmjeravao se na područja mozga i signale koji su osjetljivi na promjene u broju podražaja koji se pamte. Pretpostavljena neuralna osnova modela resursa je konstantna (Bays, 2014) ili stohastički varijabilna (van den Berg i sur., 2012) razina aktivnosti populacije neurona. Drugim riječima, modeli resursa pretpostavljaju kako je aktivnost populacije neurona koja kodira podražaje u VRP neosjetljiva na promjene

broja podražaja. Ove pretpostavke naizgled su u neskladu s istraživanjima koja su se prilikom pokušaja lokaliziranja VRP-a usmjeravala na područja mozga koja pokazuju promjene u aktivnosti s promjenom broja podražaja koji se pamti. Analizirani BOLD i EEG signali (npr. CDA) primarno odražavaju sinaptičku provodljivost, i to ekscitacijsku i inhibicijsku, a ne aktivnost akcijskih potencijala (Logothetis, 2008). Uzevši to u obzir, moguće je da populacija neurona koja kodira podražaje u VRP istovremeno pokaže fiksni broj akcijskih potencijala i varijabilno sinaptičko procesiranje s promjenom broja podražaja koji se pamti.

Unazad nekoliko godina brojni su autori predložili kako VRP ne pohranjuje podražaje u populaciji aktivnih neurona, već u tzv. 'tihim područjima' neuralne aktivnosti (Rose i sur., 2016; Sprague, Ester i Serences, 2016; M. G. Stokes, 2015). Ova hipoteza potaknuta je nalazima o različitoj uspješnosti dekodiranja podražaja koji se nalaze u fokusu i izvan fokusa pažnje (LaRocque i sur., 2013; Lewis-Peacock i sur., 2012). Specifično, u zadatku pamćenja više podražaja, spomenuta istraživanja uspješno su dekodirala karakteristike samo onih podražaja koji su eksperimentalnom manipulacijom dovedeni u fokus pažnje. Iako u različitim fazama zadatka za neke od zapamćenih podražaja nije pronađena nikakva neuralna reprezentacija, ti podražaji su uspješno dekodirani jednom kada su vraćeni u fokus pažnje. Također, sudionici su se uspješno dosjećali tih podražaja nakon što naizgled nisu imali neuralnu reprezentaciju tih podražaja. Ovi nalazi pokazuju kako ti podražaji nisu bili zaboravljeni. Autori ovih istraživanja postavili su hipotezu kako neuralni signal koji omogućava uspješno dekodiranje zapravo neuralni marker pažnje, dok se reprezentacije u VRP pohranjuju vjerojatno kroz biološke ili morfološke promjene u neuronima (M. G. Stokes, 2015). Iako će odgovor na točan mehanizam pohrane podražaja u VRP morati sačekati dodatne provjere, predloženi mehanizam 'tihe pohrane' ne čini se vjerojatnim. Schneegans i Bays (2017b) su nedavno pokazali kako pretpostavka o tihoj pohrani nije potrebna. Oni su koristeći neuralni model dinamičnog polja (Johnson, Simmering i Buss, 2014), koji se po većini svojih karakteristika podudara s modelom populacijskog kodiranja, uspješno reproducirali sve bihevioralne i neuralne nalaze prethodnih fMR studija. Kako ovaj model ne sadržava niti jednu komponentu 'tihe pohrane' već populaciju stalno aktivnih neurona, ovo istraživanje je pokazalo kako pretpostavka o neuralno 'tihim područjima' pohrane u VRP nije nužna da bi se objasnila dosadašnja istraživanja. U skladu s tim su i neka recentna neuralna istraživanja koja su detektirala aktivna područja u periodu obrade u kojem je sugerirano postojanje 'tihe pohrane' (Christophel, Iamshchinina, Yan, Allefeld i Haynes, 2018; Sprague, Ma i Curtis, 2018). Ipak, debata o točnom mehanizmu pohrane još je daleko od svog kraja, i na pitanje odvija li se pohrana u 'tihim' ili aktivnim područjima tek treba sačekati odgovor (Constantinidis i sur., 2018; Lundqvist, Herman i Miller, 2018).

Zaključno, u ovom posljednjem dijelu posvećenom pohrani u VRP prikazani su računarski modeli motivirani modelima resursa. Karakteristika svih opisanih verzija modela jest njihova

plauzibilna biološka osnova. Osim toga, iako opisuju funkcioniranje sa svega nekoliko neuralnih mehanizama, ovi modeli uspijevaju objasniti ključne nalaze istraživanja VRP-a, te reproducirati opažene uratke u eksperimentalnim situacijama. Važno je napomenuti kako ovaj pregled ne daje iscrpan uvid u postojeće modele VRP-a. Neki alternativni, više ili manje slični upravo opisanim modelima su i brojni drugi neuralni modeli VRP-a (Almeida, Barbosa i Compte, 2015; Bouchacourt i Buschman, 2018; Matthey, Bays i Dayan, 2015; Nassar i sur., 2018; Oberauer i Lin, 2017; Sims, Jacobs i Knill, 2012; Z. Wei, Wang i Wang, 2012; Yatziv i Kessler, 2018).

1.3 Interferencija u vidnom radnom pamćenju

Najvažniji zaključak prethodnog poglavlja jest kako VRP, poput gotovo svakog sustava (prirodnog ili tehničkog) funkcionira lošije kada je pod pritiskom, konkretno, povećanim brojem podražaja koji se pamti. Ako se zamislite kako obavljate bilo koji svakodnevni zadatak u kojem VRP određuje uspješnost (npr. traženje omiljene majice u ormaru), paralelno s obavljanjem tog trenutnog zadatka, VRP je pod stalnim pritiskom velikog broja ulaznih vidnih informacija nepotrebnih za izvođenje tog zadatka. Nekoliko prethodno opisanih istraživanja pokazalo je kako se reprezentacije VRP-a i prisutni distraktori natječu za iste neuralne resurse (Herwig, Beisert i Schneider, 2010; Macoveanu, Klingberg i Tegnér, 2007). Kako VRP funkcionira pod opterećenjem nebitnih, ometajućih informacija? Tema distraktora i interferirajućih efekata do kojih oni dovode predmet je istraživanja od same pojave konstrukta VRP-a. Uradak u zadatku uz prisutnost distraktora ovisi o najmanje dva široka faktora. Prvi od njih odnosi se na mogućnost zadržavanja relevantnih informacija, tj. podražaja u VRP-u, a određen je kvalitetom reprezentacija tih podražaja. Druga važna odrednica jest mogućnost zanemarivanja prisutnih distraktora, i povezana je primarno sa snagom distraktora. U ovom poglavlju prikazana su istraživanja uloge distraktora u VRP-u i glavni zaključci tih istraživanja. U poglavljima nakon posebno su opisani faktori koji određuju efikasnost distraktora.

Prije opisa istraživanja interferencije, važno je reći kako različita istraživanja koriste različite vrste distraktora. Jedna česta metoda je korištenje maskirajućeg podražaja, podražaja koji sadrži sve kvalitete vidne karakteristike koja se koristi u zadatku VRP-a (npr. sve orijentacije ili sve boje). Ovakav podražaj ponekad se naziva i bijeli šum jer na nestrukturiran način prikazuje sve potencijalne informacije koje su se mogle prikazati u zadatku pamćenja pri čemu se ispitanik niti na jednu ne može posebno usredotočiti. Istraživanja djelovanja maske pokazuju kako prikaz takvog podražaja prekida unos prethodnog podražaja u vidni sustav, zbog čega se maska često koristi kako bi se kontroliralo vrijeme kodiranja (Breitmeyer i Ogmen, 2006). Sljedeća često korištena metoda je transkranijalno magnetno podraživanje (engl. *transcranial magnetic stimulation*, TMS). Istraživanja pokazuju kako TMS signal, slično masci, dovodi do pojave kor-

tikalne inhibicije koja prekida postojeću neuralnu aktivnost (Harris, Clifford i Miniussi, 2008) i posljedično dovodi do nestanka neuralnog signala povezanog s podražajem. Posljedice prikaza maske i primjene TMS na uradak najvjerojatnije se vide u padu preciznosti i povećanoj frekvenciji pogađanja prilikom uratka u zadatku. Još jedna korištena metoda jest prikaz distraktora koji nose neku informaciju, tj. jasnog podražaja. Mehanizam djelovanja takvih distraktora može biti različit - od unošenja neuralnog šuma sve do stvaranja kompetitivnog neuralnog signala koji može zamijeniti podražaj u VRP-u. Konačno, iako i maska i TMS oponašaju neke realne situacije u svakodnevnom životu, prilikom obavljanja većine zadataka, distraktori su strukturirani vidni objekti koji mogu ometati obradu na sustavniji način od nestrukturiranog podražaja poput maske. Konkretno, distraktori koji imaju jasnu vidnu kvalitetu (npr. boju) dok trenutni zadatak zahtjeva pamćenje podražaja iste kvalitete, mogu dovesti do sustavnih pogrešaka u pamćenju, poput zamjene podražaja za pamćenje distraktorom. Neovisno o korištenoj metodi, važno je imati na umu kako je pojava određene pogreške uslijed distraktora uvelike određena vrstom distraktora.

Bihevioralna istraživanja

Tipična istraživačka paradigma za ispitivanje interferencije podrazumijeva prikazivanje vidnih podražaja tijekom obavljanja zadatka VRP-a - između prikaza ekrana za pamćenje i faze došjećanja, sudionicima se prikazuju ometajuće informacije, tj. distraktori. Prvotno, istraživanja interferencije usmjeravala su se na pitanje opće interferencije unutar VRP-a s ciljem pronalaska potvrde za odvojene sustave pohrane, npr. vidnih i prostornih informacija. Ova istraživanja dolazila su do zaključka kako su reprezentacije u VRP-u najosjetljivije na vidne distraktore (Della Sala, Gray, Baddeley, Allamano i Wilson, 1999; Hecker i Mapperson, 1997; Klauer i Zhao, 2004; Smith i sur., 1995; Tresch, Sinnamon i Seamon, 1993; Vuontela, Rämä, Raniinen, Aronen i Carlson, 1999; za suprotne nalaze vidi Vergauwe, Barrouillet i Camos, 2009; za pregled suprotnih nalaza vidi Morey, 2018). Nadalje, istraživanja su pokazala kako je sadržaj VRP-a najosjetljiviji na podražaje istih vidnih kvaliteta, u skladu s nalazima o specijalizaciji dijelova vidnog korteksa za pohranu samo određenih vidnih kvaliteta (Livingstone i Hubel, 1987; Magnussen i Greenlee, 1999; Magnussen, Greenlee, Asplund i Dyrnes, 1991; Sneve, Alnæs, Endestad, Greenlee i Magnussen, 2011; Zeki i sur., 1991). Istraživanja koja su pokušala odgovoriti na ovo pitanje kao podražajni materijali koristila su vidne podražaje koji su sastavljeni od dvije kvalitete, npr. Gaborov podražaj koji ima kvalitetu prostorne frekvencije i kvalitetu orijentacije. Klasičan nalaz je kako sudionici, kada imaju zadatak pamtit i jednu od tih kvaliteta, npr. prostornu frekvenciju, prikazivanje drugog irelevantnog podražaja (distraktora) različite prostorne frekvencije ima negativan utjecaj na uradak u zadatku; prikazivanje distraktora koji se razlikuje od zapamćenog podražaja po za istraživanje nevažnoj kvaliteti, npr. orijentaciji,

ne utječe na uradak u zadatku (Lalonde i Chaudhuri, 2002; Magnussen i sur., 1991; Nemes, Whitaker, Heron i McKeefry, 2011; Vincent i Regan, 1995).

Nalazi o interferenciji pronađeni su u brojnim istraživanjima, i to koristeći različite podražajne materijale. Pokazano je kako prikazivanje distraktora za vrijeme pamćenja orijentacija (Rademaker, Bloem, De Weerd i Sack, 2015; van Ede, Chekroud, Stokes i Nobre, 2018), prostornih frekvencija (Bennett i Cortese, 1996; Magnussen i sur., 1991; Nemes i sur., 2011), boja (Nemes, Parry, Whitaker i McKeefry, 2012; Nilsson i Nelson, 1981), smjera kretanja (Magnussen i Greenlee, 1992; McKeefry, Burton i Vakrou, 2007; Pasternak i Zaksas, 2003), lica (Jha, Fabian i Aguirre, 2004; Sreenivasan i Jha, 2007; Yoon, Curtis i D'Esposito, 2006) ili vidno-prostornih informacija (Sakai, Rowe i Passingham, 2002) dovodi do pada uratka u zadatku VRP-a (vidi još Allen, Baddeley i Hitch, 2006; Allen, Castellà, Ueno, Hitch i Baddeley, 2015; Broadbent i Broadbent, 1981; Brockmole, Wang i Irwin, 2002; Jiang i Kumar, 2004; Logie, Brockmole i Vandenbroucke, 2009; Nicholls, Parmentier, Jones i Tremblay, 2005; Ueno, Allen, Baddeley, Hitch i Saito, 2011). Nadalje, istraživanja pokazuju kako procesi pažnje imaju vrlo važnu ulogu u proizvodnji interferencije, na način da aktivna obrada distraktora dovodi do snažnijeg utjecaja distraktora na uradak u zadatku VRP-a (Klauer i Zhao, 2004; van Lamsweerde i Johnson, 2017). Važno je istaknuti kako pamćenje vidnih podražaja nije neosjetljivo na distraktore različitih vidnih kvaliteta. Makovski, Shim i Jiang (2006) su u zadatku detekcije promjene od sudionika tražili da zapamte dvije, tri ili četiri boje te detektiraju je li na sukcesivno prikazanom ekranu došlo do promjene. Pritom, sudionicima su na nekim sekvencama prikazivali ometajuće slike (životinje, prirodu, itd.). Rezultati su pokazali kako su sudionici bili lošiji u detekciji kada su im prikazivani distraktori, u odnosu na situaciju u kojoj distraktora nije bilo.

Van der Stigchel, Merten, Meeter i Theeuwes (2007) proveli su jednostavno istraživanje prostornog VRP-a u kojem su željeli provjeriti kakvo je pamćenje prostornih informacija u prisutnosti ometajućih prostornih informacija. Autori su sudionicima u svakoj sekvenci prikazali lokaciju podražaja koju su trebali zapamtiti tijekom kratkog perioda. Ključno, na nekim sekvencama se tijekom faze zadržavanja na ekranu pojavio novi, ali nevažni podražaj i to na novoj lokaciji. Rezultati su pokazali kako je lokacija koje su se sudionici dosjetili bila sustavno pomaknuta prema lokaciji prikazanog distraktora.

Postojanje interferirajućeg utjecaja distraktora na sadržaje VRP-a je relativno dobro potvrđen nalaz (za suprotne nalaze vidi npr. Bettencourt i Xu, 2016; Rademaker, Chunharas i Serences, 2018). Međutim, pad uratka u zadacima VRP može imati različite izvore, a "sudbina" reprezentacija u VRP-u može biti raznolika. Jedna mogućnost je kako distraktori istih vidnih kvaliteta kao i podražaji pohranjeni u VRP-u unose šum u zapamćene reprezentacije i dovode do smanjenja njihove preciznosti dosjećanja (Magnussen i Greenlee, 1992). Ova hipoteza počiva na pretpostavci kako su vidne informacije pohranjene u neuronima udešenima za pohranu

specifičnih vidnih informacija određene kvalitete (npr. samo određenu orijentaciju), te da aktivni neuroni mehanizmom lateralne inhibicije inhibiraju aktivnost drugih susjednih neurona. Do gubitka informacija u VRP-u dolazi kada neuroni koji pohranjuju informacije o distraktoru inhibiraju aktivnost ranije aktiviranih neurona koji pohranjuju sadržaje u VRP-u. Myers, Stokes, Walther i Nobre (2014) su sudionicima sekvencijalno prezentirali podražaje različitih orijentacija i tražili da se dosjete jednog od njih. Nizovi koje su im prikazivali bili su duljine tri i četiri podražaja, pri čemu je četvrti podražaj u dijelu sekvenci označen kao distraktor i sudionici su ga trebali ignorirati, a na dijelu sekvenci kao podražaj koji trebaju upamtiti. Na taj način, sudionici su u dvije situacije pamtili tri podražaja (jednom s distraktorom i jednom bez distraktora), a u jednoj četiri. Usporedba dosjećanja u dvije situacije kada su sudionici pamtili tri podražaja pokazala je lošije dosjećanje kada je prikazan četvrti distraktirajući podražaj kojeg su sudionici trebali ignorirati. Provjera pristajanja modela mješovitih distribucija s komponentama točnog dosjećanja i slučajnog pogađanja pokazala je kako u situaciji s distraktorom pada preciznost dosjećanja zapamćenog podražaja, ali se ne mijenja vjerojatnost točnog dosjećanja. Ovaj rezultat u skladu je s pretpostavkom kako distraktirajući podražaji unose šum u reprezentacije zapamćenih podražaja.

Nekoliko istraživanja predložilo je kako je porast reprezentacijskog šuma posljedica uprosječivanja različitih specifičnih mehanizama interferencije. Specifično, distraktori mogu dovesti do različitih vrsta pristranosti kod dosjećanja sadržaja VRP-a, poput npr. *efekta privlačenja* ili *efekta odbijanja*. Istraživanja su pokazala kako ovi efekti ovise o samoj sličnosti podražaja na način da distraktor koji je različit od sadržaja VRP-a dovodi do efekta privlačenja (dosjećanje je sustavno pomaknuto prema kvaliteti, npr. orijentaciji, distraktora), dok vrlo sličan distraktor dovodi do efekta odbijanja kod dosjećanja (dosjećanje je sustavno odmaknuto od kvalitete distraktora) (Golomb, 2015). Nadalje, čini se kako ova dva efekta ovise i o prostornom razmještanju podražaja koji se pamti na način da se lokacije bliskih podražaja dovode do efekta privlačenja, a lokacije udaljenih podražaja do efekta odbijanja (Almeida i sur., 2015). Osim neuralne plauzibilnosti (Baars i Gage, 2010) ovaj mehanizam ima svoju podršku i u bihevioralnim istraživanjima koja pokazuju mali efekt distraktora kada je on identičan ili vrlo različit podražaju u pamćenju dok je efekt najsnažniji za relativno slične podražaje (npr. 30° - 40° pomaka na krugu boja; Kiyonaga i Egner, 2016; Störmer i Alvarez, 2014).

Huang (2010) je ponudio još jedan mehanizam kojim distraktori mogu djelovati na VRP, specifično mehanizam *uprosječivanja*. On je sudionicima sukcesivno prikazivao podražaje različitih prostornih frekvencija, a zatim tražio od njih da se dosjete prostorne frekvencije jednog od njih. Rezultati istraživanja su pokazali kako je dosjećanje prostorne frekvencije jednog podražaja pokazivalo efekt privlačenja prema prostornoj frekvenciji drugog podražaja. Na temelju ovih rezultata predložen je mehanizam prema kojem se podražaji različite prostorne frekvencije

uprosječuju u zajedničku reprezentaciju, pri čemu informacija iz svakog podražaja pridobije ponder proporcionalan važnosti tog podražaja (npr. mehanizmom selektivne pažnje) (Dubé, Zhou, Kahana i Sekuler, 2014; Huang, 2010). Rademaker i sur. (2015) su u zadatku VRP-a tražili od sudionika da zapamte orijentaciju Gaborovog podražaja. Između faza kodiranja i dosjećanja sudionicima su prikazivani distraktirajući Gaborovi podražaji pri čemu je kontrolirana sličnost orijentacija. Kroz četiri eksperimenta pokazano je kako pogreška dosjećanja ovisi o sličnosti podražaja i distraktora: kada su podražaj u VRP-u i distraktor bili iste orijentacije, dosjećanja su bila preciznija u usporedbi s kontrolnom situacijom bez distraktora; kada su se distraktor i podražaj u VRP-u razlikovali, dosjećanja su bila manje precizna pri čemu veličina razlike nije utjecala na veličinu pogreške. U istom istraživanju pokazan je značajan efekt privlačenja na način da su sudionici prilikom dosjećanja orijentacija sustavno davali odgovore koji su bili sličniji orijentaciji distraktora. Ponovno, taj efekt nije se mijenjao linearno s veličinom razlike između dvije orijentacije, suprotno hipotezi uprosječivanja koja pretpostavlja kako će pogreška dosjećanja biti to veća što se dvije orijentacije više razlikuju (prosjeck dvije orijentacije sve više odstupaju od orijentacije za dosjećanje).

U području istraživanja VRP-a, često istraživana vrsta pogrešaka dosjećanja su pogreške zamjene, tj. slučajne zamjene podražaja traženog za dosjećanje i nekog od preostalih prikazanih podražaja (Bays i sur., 2009; Schneegans i Bays, 2017a). Tipično, analiza dosjećanja u zadacima VRP-a pokazuje kako je količina takvih pogrešaka značajna (Bays i sur., 2009; Schneegans i Bays, 2016). Uvid u ovu vrstu pogrešaka pokazuje koliko dobro sudionici povezuju različite karakteristike podražaja - one kojih se trebaju dosjetiti (npr. boja) i onih koji služe kao znak za dosjećanje (npr. lokacija) - u jedinstvenu reprezentaciju podražaja. U području istraživanja interferencije, jedna od mogućih hipoteza jest kako distraktori unose dodatni šum u vidne reprezentacije zbog čega sudionici češće rade pogreške zamjene s nekim od podražaja iz VRP-a. Osim toga, utjecaj distraktora može biti puno sustavniji. Konkretno, distraktori mogu ostvariti utjecaj intruzijom u reprezentacije u VRP-a, a pritom možemo pretpostaviti kako će ta intruzija biti češća kada distraktori i podražaji za pamćenje dijele neku od karakteristika (npr. lokaciju). I ova vrsta pogrešaka odražava nedovoljno formiranu reprezentaciju objekta u VRP-u.

Fallon, Mattiesing, Dolfen, Manohar i Husain (2018) proveli su istraživanje kojim je moguće odgovoriti na neke od hipoteza o ulozi distraktora u pogreškama zamjene. U tom istraživanju, sudionici su u tipičnom zadatku VRP-a vidjeli dvije različito obojene linije razmještene na ekranu, a zadatak je bio da zapamte orijentacije tih linija, dok su boje linija služile kao znak za dosjećanje. Između faze pamćenja i faze dosjećanja sudionicima su prikazane druge dvije linije (distraktori) koje su morali ignorirati. Analiza pogrešaka zamjena usporedbom situacije s distraktorima i situacije bez distraktora pokazala je kako su te pogreške zamjene drugog podražaja i distraktora (intruzije) češće uslijed prikaza distraktora. Nadalje, važno je analizirati izvore tih

pogrešaka - dosjećaju li se sudionici pogrešno drugog, netraženog podražaja iz VRP-a, ili nekog od prikazanih distraktora. Iako autori rada ne prikazuju te rezultate, dodatnom analizom deskriptivnih pokazatelja danih u radu, vidljivo je kako su proporcije pogrešaka zamjene netraženog podražaja iz VRP-a podjednake u situaciji sa i bez distraktora, te da opaženi rast pogrešaka zamjena uslijed prikaza distraktora proizlazi iz pogrešnog navođenja orijentacije distraktora. Ovaj nalaz vrlo je važan jer pokazuje kako distraktori interferirajući efekt ostvaruju i intruzijom, a ne samo unošenjem šuma koji može za posljedicu imati brojne druge pogreške (podaci prikupljeni iz originalnog rada alatom za analizu grafova (<http://arohatgi.info/WebPlotDigitizer/>)).

van Ede, Chekroud i sur. (2018) su u istraživanju koristili Gaborove podražaje čije su orijentacije sudionici morali zapamtiti. Između faze kodiranja i dosjećanja, sudionicima je u nekim sekvencama prikazan distraktor, također Gaborov podražaj. Kada je sudionicima u fazi zadržavanja prikazan distraktor, pogreške dosjećanja su značajno porasle. Osim toga, sudionici su u otprilike 2% odnosno 6% slučajeva reproducirali orijentaciju distraktora odnosno pogađali orijentaciju traženog podražaja. Važno je istaknuti kako su sudionici pamtili samo jedan podražaj te imali vrlo dugo vrijeme kodiranja (500ms). Uz ovakve eksperimentalne postavke, teško je očekivati pogreške zamjene i pogađanje, čime su rezultati ovog istraživanja još impresivniji.

Aagten-Murphy i Bays (2017) su demonstrirali utjecaj distraktora na sakade. Autori su u istraživanju tražili od sudionika da u što kraćem vremenu nakon prikaza podražaja usmjere pogled na podražaj određene boje na ekranu. Pritom, na ekranu su uvijek bila prikazana dva podražaja pri čemu je jedan bio tražene boje, dok je drugi predstavljao distraktor. U istraživanju je manipulirano prostornom razmaknutosti traženog podražaja i distraktora, a hipoteza autora je bila kako će distribucija sakada biti kombinacija sakada na traženu lokaciju, sakada na lokaciju distraktora, te sakada na lokaciju između traženog podražaja i distraktora (tzv. 'globalni efekt', Coren i Hoenig, 1972). Rezultati su potvrdili hipotezu i pokazali kako distraktirajući podražaj u jednostavnom zadatku pokreta očima može u potpunosti odvući sakade od traženog podražaja (sakade na lokaciju distraktora) te utjecati na preciznost sakada na traženi podražaj (sakade na lokaciju između dva podražaja). Taj efekt je bio snažniji što su dva podražaja prostorno bila bliža, no ostao je stabilan neovisno o trajanju sakada. Drugim riječima, čak i kada su pokreti očima prema traženom podražaju bili relativno spori, distraktori su i dalje u značajnoj mjeri doveli do pogrešaka u sakadama.

U dosadašnjem dijelu teksta o interferenciji u VRP-u dan je kratak pregled istraživanja uloge distraktora u zadacima VRP-a. Zaključak ovog pregleda jest kako su efekti distraktora dobro potvrđeni, ali i da ovise o vrsti distraktora. Osim toga, efekti do kojih distraktori dovode mogu se razmatrati na općenitoj razini pada uratka u zadatku, ali i na znatno specifičnoj razini, razmatrajući vrstu pogrešaka ili pristranosti dosjećanja. U sljedećem dijelu teksta dan je prikaz neuralnih istraživanja interferirajućih efekata, a naglasak je stavljen na istraživanja koja su

ispitivala mehanizam djelovanja distraktora.

Neuralna istraživanja

Prvotna neuralna istraživanja interferencije usmjeravala su se na tradicionalno pretpostavljene neuralne markere VRP-a. Vogel i sur. (2005) proveli su istraživanje u kojem su koristili CDA kao neuralni korelat obrade distraktora. Oni su na temelju uratka u zadatku VRP-a podijelili sudionike u skupine onih s niskim i visokim kapacitetom VRP-a. Njihova pretpostavka bila je kako su oni s visokim kapacitetom bolji u ignoriranju distraktora prilikom obavljanja zadatka, dok oni s niskim kapacitetom pohranjuju i bitne i nebitne podražaje. Na temelju prethodnih nalaza o korelaciji amplitude CDA s brojem podražaja u VRP-a autori su pretpostavili kako će kod sudionika s visokim kapacitetom pronaći ranije opaženi porast u amplitudi s porastom broja podražaja koji se pamti. S druge strane, pretpostavili su da će kod sudionika s niskim kapacitetom CDA odražavati ukupan broj podražaja u zadatku - i bitnih i distraktora. Rezultati su pokazali kako kod sudionika s niskim kapacitetom nije bilo razlike u CDA između situacija kada su u zadatku imali 2 podražaja za pamćenje i 2 distraktora i kada su morali pohraniti 4 podražaja u VRP. Drugim riječima, sudionici s niskim kapacitetom neefikasno pohranjuju sve informacije, čak i distraktore koje su morali ignorirati. I druga istraživanja slijedila su ovu logiku i došla do sličnih zaključaka kako je pamćenje podražaja i ignoriranje distraktora pod jedinstvenom kontrolom rada VRP-a (Bonfond i Jensen, 2012). Iako je CDA još uvijek čest predmet istraživanja u području VRP-a, neka novija istraživanja poput onoga Noonan i sur. (2016), pokazala su kako različiti mehanizmi facilitiraju pohranu podražaja u VRP-u i inhibiraju pohranu distraktora. Konkretno, alpha valovi koji se smatraju neuralnim markerom VRP-a pokazuju modulaciju u amplitudi kada se eksperimentalno facilitira pohrana podražaja u VRP, ali ne i kada se inhibiraju distraktori. Ovaj nalaz govori kako u pozadini obrade podražaja VRP-a i distraktora ne postoji jedan neuralni signal, poput alpha valova ili povezanog im CDA signala.

U skladu s drugim istraživanjima koja su pokazala kako alpha valovi i CDA ne predstavljaju jednoznačan neuralni marker VRP-a, ova ideja počela se napuštati i u području istraživanja interferencije. Osim toga, CDA nema ishodište u jednom izoliranom mozgovnom području i mogućnost lokalizacije neuralne strukture uključene u obradu VRP-a i distraktora istraživanjem ovog signala je ograničena. S druge strane, neuralna istraživanja interferencije u VRP-u trebaju odgovoriti na barem dva pitanja: prvo, koji neuralni mehanizam omogućava "obranu" reprezentacija od distraktora, i drugo, gdje su pohranjene reprezentacije VRP-a koje su otporne na distraktore. Kompleksnije analitičke metode poput MVPA i anatomske preciznije metode mjerenja neuralne aktivnosti poput fMR postale su standard u ovim istraživanjima.

Clapp, Rubens i Gazzaley (2010) u dva su eksperimenta ispitivali funkcioniranje VRP-a uz prikazivanje relevantnih distraktora (sudionici su morali usmjeriti pažnju na distraktore) i irelevantnih distraktora (sudionici su ih morali ignorirati), te mjerili neuralnu aktivnost pomoću EEG i fMR. Rezultati oba eksperimenta konvergirali su zaključku kako relevantni distraktori prekidaju komunikaciju prefrontalnih i perceptivnih dijelova mozga. Slično istraživanje proveli su Dolcos, Miller, Kragel, Jha i McCarthy (2007) prikazujući sudionicima kongruentne i nekongruentne (šum) distraktore. Uradak sudionika bio je lošiji kada su distraktori bili slični materijalu koji se pamtio, i to u usporedbi s uratkom u sekvencama kada je period zadržavanja bio bez distraktora i kada je bio ispunjen vidnim šumom. Neuralni podaci su pokazali aktivaciju prefrontalnih i posteriornih dijelova mozga, pri čemu su posebnu ulogu u pohrani podražaja u VRP i inhibiciji distraktora imali dorzolateralni PFC odnosno ventrolateralni PFC.

Jha i sur. (2004) su sudionicima tijekom zadatka VRP-a prikazivali distraktore koji su bili kongruentni ili nekongruentni s materijalom koji se pamtio, te opažali fMR signale tijekom obavljanja tog zadatka. Analiza bihevioralnih rezultata pokazala je sporije reagiranje i slabiji uradak kada su distraktori i podražaji za pamćenje bili kongruentni. Analiza neuralnih signala pokazala je snažniju aktivnost u lijevom ventrolateralnom dijelu PFC na kongruentnim sekvencama. Važno, snažnija aktivacija opažena je samo u sekvencama s točnim detekcijama u zadatku VRP-a. Ovi rezultati sugeriraju kako su dijelovi PFC ključni u smanjivanje interferencije. Yoon i sur. (2006) u sličnom su istraživanju pronašli kako kongruentni distraktori dovode do smanjivanja funkcionalne povezanosti između prefrontalnih dijelova, koji prema autorima pohranjuju informacije, i senzornih dijelova mozga, koji obrađuju distraktore. I druga istraživanja istaknula su važnu ulogu dijelova PFC, i to u nekoliko bitnih funkcija poput pridavanja odnosno odvlačenja pažnje od distraktora, pohrane informacija, te reaktivacije reprezentacija kada je pohrana narušena (Aron, Robbins i Poldrack, 2004; D'Esposito, Postle, Ballard i Lease, 1999; D'Esposito, Postle, Jonides i Smith, 1999) (vidi B. Postle, Druzgal i Desposito (2003) za izostanak uključenosti PFC u obranu od distraktora).

Sakai i sur. (2002) od sudionika su tražili da pamte sekvencijalno prikazane vidno-prostorne podražaje, te da u fazi zadržavanja obavljaju distraktirajući zadatak koji je također sadržavao vidno-prostorne podražaje. Tijekom sekvenci na kojima su distraktori bili prikazani, a sudionici točno odgovorili u zadatku pamćenja, neuralna aktivnost mjerena fMR pokazala je stabilnu amplitudu u prefrontalnim dijelovima i inferiornom parijetalnom sulkusu (IPS), i to neovisno o trajanju faze retencije (8–16s). Usporedba s aktivnosti opaženom na sekvencama s netočnim odgovorom pokazala je modulaciju aktivnosti dijela DLPFC (dorsolateralni prefrontalni korteks, područje 46). Pritom, razlike u amplitudi signala mogle su se opaziti i prije same prezentacije distraktora. Na temelju toga, autori su zaključili kako ovo područje omogućava zaštitu reprezentacija od distraktora, te da se otporne reprezentacije formiraju vrlo rano nakon prikaza

podražaja. Preostala prefrontalna i parijetalna područja koja su pokazala povišenu i stabilnu aktivnost na točnim i netočnim sekvencama mogla bi služiti za pohranu očuvanih reprezentacija.

Feredoes, Heinen, Weiskopf, Ruff i Driver (2011) su željeli utvrditi točnu ulogu prefrontalnih dijelova mozga u obavljanju zadatka VRP-a u kontekstu interferencije. Oni su od sudionika tražili da zapamte jednu od dvije vrste podražaja, lica ili kuće, te im u fazi zadržavanja, u dijelu sekvenci, prezentirali distraktore koji su uvijek bili iz kategorije podražaja suprotne zapamćenim podražajima. Ova manipulacija je ključna jer su se podražaji za pamćenje i distraktori kodirali u različitim senzornim dijelovima mozga. Tijekom obavljanja zadatka sudionicima su TMS podraživali DLPFC i promatrali u kojem od posteriornih dijelova mozga, onima koji kodiraju podražaje za pamćenje (npr. lica) ili distraktore (npr. kuće) će doći do promjene aktivnosti uslijed TMS podraživanja. Dva su moguća ishoda ovakvog istraživanja: DLPFC ostvaruje utjecaj zaštitom podražaja za pamćenje (TMS bi trebao imati posljedicu na aktivnost područja koji pohranjuju reprezentacije) ili inhibicijom distraktora (TMS bi trebao imati posljedicu na aktivnost područja koji pohranjuju distraktore). Rezultati su pokazali kako je DLPFC-TMS podraživanje imalo samo efekt kada su bili prikazani distraktori, pokazujući kako ovo područje nije direktno povezano s pohranom, već s kontrolom VRP-a. Nadalje, podraživanje TMS odrazilo se samo na aktivnost u područjima koja su pohranjivala reprezentacije, a ovaj nalaz snažno govori kako je uloga prefrontalnih dijelova mozga u zaštiti sadržaja VRP-a, a ne u inhibiciji distraktora.

Pojavom MVPA metoda analize fMR signala, informativnost amplitude neuralne aktivnosti za vrijeme obavljanja nekog zadatka pala je u drugi plan i danas neuralna istraživanja redovito pokušavaju otkriti koliko je opaženi signal informativan, odnosno koliko je obrazac neuralne aktivnosti opažen tijekom obrade podražaja prediktivan za karakteristike podražaja koji se pamti. Bettencourt i Xu (2016) proveli su jedno od prvih istraživanja koje je primijenilo MVPA metodu obrade neuralnih signala u zadatku VRP-a koristeći distraktore. Autori su pretpostavili kako senzorna vidna područja mogu pohranjivati sadržaje VRP-a, ali samo kada faza zadržavanja tih sadržaja nije opterećena distraktorima. U prisutnosti distraktora, područja koja nisu uključena u procesiranje senzornih informacija, ali jesu u pohranu VRP, poput superiornog IPS (sIPS), sadržavat će informacije o sadržaju VRP-a. Njihovo istraživanje potvrdilo je ovu hipotezu: kada u zadatku nisu prikazani distraktori, područja V1–V4 i sIPS pokazali su mogućnost dekodiranja podražaja iz VRP-a. Kada su u odvojenom zadatku prikazani distraktori, dekodiranje je bilo iznad slučajnog samo za sIPS. Kako se bihevioralni uradak nije razlikovao između situacije s distraktorima i bez njih, autori su zaključili kako gubitak informacija iz vidnih područja nije ključan za obavljanje ovog zadatka, te da sIPS ima ključnu, a vidna područja pomoćnu ulogu u pohrani u VRP. Jedan od rezultata u provedenom istraživanju ipak stavlja sumnju u opravdanost tog zaključka. Naime, kada su u odvojenom eksperimentu autori po

slučaju odabrali na kojoj će se sekvenci prikazivati distraktori, ponovno su i V1–V4 i sIPS pokazali mogućnost dekodiranja informacija i to u prisutnosti i odsutnosti distraktora. Na temelju pretpostavki autora i prethodno opisanog eksperimenta, sIPS bi trebao sadržavati informacije o VRP-u uvijek, a V1–V4 samo kada nisu prikazani distraktori. Autori su interpretirali ovaj nalaz na način da sudionici strateški "isključuju" vidna područja kada su sigurni da će distraktor biti prikazan. Ovo je malo vjerojatno objašnjenje iz dva razloga (E. F. Ester, Rademaker i Sprague, 2016). Prvo, u eksperimentu s prediktivnim distraktorima, uradak sudionika se nije razlikovao između situacija sa i bez distraktora. Nejasno je zašto bi sudionici strateški "uključivali" ova područja kada ona ne doprinose uratku. Drugo, prediktivnost distraktora je rijetka u svakodnevnim zadacima i predstavlja umjetnu situaciju zbog čega rezultati s neprediktivnim distraktorima vjerojatnije odražavaju karakteristike neuralnog sustava i pohranu VRP-a.

Općenito, pretpostavlja se kako VRP zadržava reprezentacije održavajući razinu neuralne aktivnosti sličnu onoj opaženoj uz početne faze kodiranja (D'Esposito i Postle, 2015). Prikazivanje distraktora može izazvati aktivnost sličnu onoj vezanoj uz zapamćene podražaje, što može dovesti do interferencije dva neuralna koda. Za adaptivno funkcioniranje, neuralni kod vezan uz reprezentacije VRP-a bi se u prisutnosti distraktora trebao promijeniti. Ovu hipotezu željeli su provjeriti Derrfuss, Ekman, Hanke, Tittgemeyer i Fiebach (2017). Oni su od sudionika tražili da zapamte vidne podražaje (lica ili kuće) tijekom perioda od 24 sekunde, te su im usred tog perioda na 6s prikazivali distraktirajući materijal. Snimajući neuralnu aktivnost fMR, autori su mogli analizirati podatke o relativno dugačkom periodu zadržavanja prije, tijekom i nakon prezentacije distraktora. Rezultati su pokazali kako sadržaj VRP-a može biti dekodiran u svim fazama obrade, i to iz okcipitalnih, temporalnih i parijetalnih, ali ne i frontalnih područja. Klasifikatori trenirani na periodu prije prezentacije distraktora uspješno su dekodirali podražaje na temelju signala opaženog nakon prezentacije distraktora, ali ne i na temelju signala opaženog tijekom prezentacije distraktora. Ovaj nalaz upućuje na to kako je neuralna aktivnost u pozadini VRP-a privremeno promijenjena tijekom prezentacije distraktora i oporavljena nakon distraktora. Jedan od najvažnijih zaključaka ovog istraživanja jest kako vidna područja sadrže informacije o VRP-u čak i uz prikaze distraktora.

U skladu s tim nalazom su i nedavna istraživanja Lorenc i sur. (2018) i Rademaker, Chunharas i Serences (2018). U oba istraživanja autori su od sudionika tražili da zapamte orijentaciju jednog podražaja za kasnije dosjećanje. U fazi zadržavanja, sudionicima su prikazivani distraktirajući podražaji, a autori su željeli provjeriti gdje se odvija pohrana reprezentacija u prisutnosti ometajućih podražaja. Oba istraživanja pokazala su uspješno dekodiranje informacija iz vidnih područja. Specifično, Lorenc i sur. (2018) su pronašli kako su informacije redundantno pohranjene u senzornim i IPS području kada sudionici očekuju distraktore, te da se kod izostanka distraktora smanjuje informativnost IPS. Zaključak ovog istraživanja je kako vidna područja

igraju ključnu ulogu u pohrani VRP-a, dok se IPS uključuje kao pomoćno neuralno područje kada je VRP opterećeno distraktorima. Nadalje, dekodiranje informacija o VRP-u iz vidnih područja pokazalo je pristranost dosjećanja u smjeru kvalitete distraktora, rezultat koji sugerira kako reprezentacije VRP-a i distraktori koegzistiraju barem djelomično u istim područjima. Rademaker, Chunharas i Serences (2018) su uspješno dekodirali i reprezentacije VRP-a i prikazane distraktore u područjima uzduž vidne hijerarhije (V1–V4, LOC, IPS). Pritom, autori su predložili mehanizam (engl. *region-wide multiplexing*) prema kojem više informacija može koegzistirati u istim područjima: reprezentacije iz VRP-a nalaze se primarno u nižim slojevima kore (u skladu s drugim *odozgo-prema-dolje* informacijama), dok nove senzorne informacije iz talamusa (lateralnog koljenastog tijela) pristižu uglavnom u srednje slojeve (sloj 4) vidnog korteksa.

Zaključno, ova istraživanja istaknula su ključnu ulogu PFC i posteriornih, parijetalnih i okcipitalnih dijelova mozga u funkcioniranju VRP-a uz prisutnost distraktora. Nalazi ovih istraživanja pokazuju kako zahtjevi zadatka dovode do adaptivnog kodiranja podražaja, pri čemu je komunikacija frontalnih i posteriornih područja ključna u zaštiti reprezentacija pohranjenih u VRP-u. Ovaj nalaz u skladu je i s prethodno prezentiranim istraživanjima neuralne osnove VRP-a koja su pokazala kako je funkcija frontalnih dijelova kore najvjerojatnije kontrola pohranjenih podražaja. S druge strane, čini se kako su podražaji u VRP-u, u prisutnosti distraktora jednako kao i u njihovom odsustvu, pohranjeni u distribuiranoj neuralnoj mreži koja uključuje okcipitalna i parijetalna područja. Važno je naglasiti i kako odabir podražajnog materijala ali i ometajućeg materijala u znatnoj mjeri određuje koja će neuralna područja biti aktivna i informativna tijekom obavljanja zadatka. Na primjer, istraživanja koja koriste bazične podražaje (npr. orijentacije) u većoj mjeri pronalaze ulogu senzornih područja, dok istraživanja koja koriste kompleksnije podražaje (npr. lica, objekti) pronalaze veću ulogu PFC.

1.4 Snaga distraktora

Jedan od čimbenika koji određuje uradak u zadatku tijekom prikazivanja distraktora jest i snaga ometajućeg materijala, tj. distraktora. Distraktori koji zahtijevaju više angažmana i više neuralnih resursa trebali bi u pravilu dovesti i do većih posljedica na uradak u zadatku VRP-a. Na primjer, aktivna obrada, tj. pridavanje pažnje distraktorima, dovodi do snažnijih interferirajućih efekata (Klauer i Zhao, 2004; Wang, Theeuwes i Olivers, 2018). Uloga snage distraktora tradicionalno je istraživana u kontekstu ispitivanja svjesne i nesvjesne obrade informacija, pri čemu su istraživanja za cilj imala usporediti interferirajuću snagu subliminalnih i supraliminalnih distraktora. Ova istraživanja imaju teorijski temelj u klasičnoj psihofizici koja pretpostavlja postojanje neke vrste praga u svjesnoj percepciji koji dijeli podražaje različite snage u dvije

odvojene kategorije - svjesno percipirani i nepercipirani. S druge strane teorija detekcije signala (D. M. Green i Swets, 1966) pretpostavlja kako su i najslabiji podražaji (slabo) kodirani, odnosno pretpostavlja gradacijski odnos snage podražaja i snage kojom je taj podražaj neuralno reprezentiran. Subliminalni podražaji u tradicionalnoj psihofizici imaju poseban status, dok u TDS predstavljaju podražaje čija snaga u odnosu na druge podražaje odgovara preciznosti neuralne reprezentacije tog podražaja. Iako u istraživanjima percepcije TDS u pravilo bolje objašnjava podatke od modela koji pretpostavljaju postojanje praga (Macmillan i Creelman, 2005), odgovor na ovo pitanje i dalje je predmet istraživanja (Asplund, Fougner, Zughni, Martin i Marois, 2014; Balsdon i Clifford, 2018; Peters i Lau, 2015; Sergent i Dehaene, 2004).

Bihevioralna istraživanja

Uloga snage podražaja u psihičkom doživljavanju predmet je psihofizičkih istraživanja. Psihofizička krivulja koja prikazuje prepoznatljivi sigmoidalan odnos intenziteta podražaja i mogućnosti detekcije tog podražaja pokazuje kako s porastom intenziteta podražaja raste i psihički doživljaj tog podražaja (Foley i Legge, 1981; Snowden i Hammett, 1998). de Gardelle, Kouider i Sackur (2010) su sudionicima prikazivali orijentacije praćene maskirajućim podražajem, a zadatak sudionika je bio da odmah po nestanku maske reproduciraju orijentaciju koju su vidjeli, te njenu vidljivost. U ovakvom perceptivnom zadatku bez faze zadržavanja, preciznost reprodukcije orijentacija rasla je s povećanjem procjena vidljivosti. Ovi rezultati upućuju na to i kako su distraktori različite snage pohranjeni razinama preciznosti koja korelira sa snagom podražaja. Novija istraživanja proširuju ove nalaze i na zadatke pamćenja, te pokazuju isti odnos koristeći druge mjere uratka, poput preciznosti dosjećanja. Bays (2016b) je koristeći zadatak s pamćenjem jedne orijentacije manipulirao kontrast podražaja koji se pamtio i pokazao kako količina resursa (pretpostavljene neuralne aktivnosti) pridana podražajima raste s povećanjem kontrasta, tj. senzorne snage tog podražaja.

Ako snaga podražaja dovodi do bolje detekcije i preciznije pohrane tog podražaja, mogu li snažniji distraktori dovesti do snažnijeg efekta na uradak u zadatku VRP-a? U skladu s idejom praga osjetljivosti koji određuje svjesnu obradu informacija, ovo pitanje često je ispitivano uspoređujući utjecaje subliminalnih i supraliminalnih distraktora. Bona i sur. (2013) proveli su istraživanje u kojem su sudionici pamtili orijentaciju jednog podražaja i na kraju svake sekvence uspoređivali s orijentacijom prikazanog testnog podražaja. U pola sekvenci sudionicima je subliminalno prikazan podražaj različitih orijentacija (0° , $\pm 10^\circ$ ili $\pm 40^\circ$ u odnosu na zapamćeni podražaj) čiju su vidljivost sudionici procjenjivali na kraju svake sekvence. Uradak u ovom zadatku pao je kada se distraktor bitno razlikovao od podražaja u VRP-u, pri čemu je taj pad bio snažniji kada je procijenjena vidljivost distraktora bila niža. Drugim riječima, ovo istraživanje

je pokazalo interferirajući efekt distraktora, pri čemu su, donekle neočekivano, slabiji distraktori (manje vidljivi) ostvarili snažniji efekt od snažnije vidljivih distraktora. U skladu s ovim nalazima su i druga istraživanja uloge subliminalnih distraktora u VRP-u (npr. Silvanto i Soto, 2012; vidi Rademaker i sur., 2015 za suprotne nalaze). Važno je napomenuti kako je definiranje snage distraktora na temelju njegove procijenjene vidljivosti donekle problematično i podložno pristranostima donošenja odluka (Peters, Ro i Lau, 2016; Schmidt, 2015) što otvara alternativne interpretacije opaženih efekata.

Snaga interferirajućeg podražaja konceptualizirana u ovom istraživanju ne pretpostavlja postojanje praga svjesnog doživljavanja, već razmatra snagu distraktora u terminima opterećenja kojeg oni predstavljaju na kognitivne resurse, bilo manipulacijom količine distraktora ili trajanjem njihove obrade. U skladu s takvim pogledom na snagu distraktora je i nedavno istraživanje Vissers, Gulbinaite, van den Bos i Slagter (2017) koje je provjeravalo ulogu snage distraktora manipulirajući brojem distraktora prikazivanih sudionicima tijekom zadatka pamćenja boja. Konkretno, autori su sudionicima u zadatku detekcije promjene uvijek prikazivali šest podražaja od kojih su tri predstavljali podražaje za pamćenje (obojeni krugovi), a preostala tri distraktore (obojeni kvadrati). U situaciji niskog opterećenja distraktorima, svi distraktori bili su iste boje, dok su u situaciji visokog opterećenja svi distraktori bili različite boje. Rezultati su pokazali značajan efekt snage distraktora na točnost detekcije u zadatku VRP-a, i to isključivo na sekvencama kada nije došlo do promjene (sudionici su češće davali lažne uzbune).

Slično, Robison, Miller i Unsworth (2018) proveli su istraživanje koristeći različit broj distraktora (0, 2 i 4), te pokazali kako uradak u zadatku detekcije promjene pada kontinuirano s povećanjem broja distraktora. Autori su sudionicima istovremeno prikazivali podražaje za pamćenje i distraktore. U fazi odgovaranja ponovno je prikazan ekran sa svim podražajima koji su se pamtili te je jedan od njih označen kao ključan, a sudionici su morali detektirati je li došlo do promjene tog konkretnog podražaja za pamćenje. Važno je napomenuti i kako je testni ekran sadržavao i podražaje za pamćenje i distraktore, te ovo istraživanje ne može razdvojiti interferenciju u fazi kodiranja i dosjećanja, te jednako vjerojatno odražava kumulativni interferirajući efekt kao i interferenciju nastalu samo u jednoj od ove dvije faze.

Schroeder, Ball i Busch (2018) također su testirali ulogu snage distraktora u zadatku VRP-a. Sudionicima je u tom istraživanju prikazivan različit broj orijentacija koje su trebali upamtiti, a tijekom faze kodiranja i zadržavanja podražaja u VRP-u, prikazivani su im distraktori različite snage. Kao distraktori korištene su linije s jasnim orijentacijama (snažni distraktori) i kvadrati (slabi distraktori). Rezultati su pokazali veću preciznost dosjećanja uz manji broj podražaja koji se pamti te slabije distraktore, dok je interakcija ovih faktora bila rubno statistički neznačajna s trendom većeg efekta snage distraktora uz manji broj podražaja koji se pamti. Analiza pogađanja prilikom dosjećanja pokazala je značajno niže proporcije pogađanja uz manji broj podražaja

koji se pamtio i slabije distraktore, dok je interakcija pokazala veću razliku snage distraktora kod pamćenja većeg broja podražaja.

Neuralna istraživanja

Većina neuralnih istraživanja senzorne snage podražaja usmjeravala se na pitanje kako su podražaji različite snage pohranjeni u VRP-u, a samo su rijetka istraživanja ispitivala kakva je neuralna osnova distraktora različite snage. Dehaene, Changeux, Naccache, Sackur i Sergent (2006) predložili su taksonomiju sublimalnog i svjesnog procesiranja u kojem snaga podražaja određuje vrstu senzornog iskustva. Specifično, slabi ili ometeni (maskirani) signali dovode do sublimalnog doživljaja, dok snažni signali dovode do doživljaja koje karakterizira određena vrsta svijesti. Ova taksonomija nije nužno vezana uz VRP, već uz vidnu percepciju zbog čega može poslužiti kao okvir i za razmatranje snage distraktora. Signali male senzorne snage rezultiraju u pravilu slabom aktivacijom u ranim vidnim područjima koja nestaje u kratkom periodu, ali uz usmjeravanje pažnje može dovesti do neuralnog signala unaprijed, no bez da se takva aktivacija prenese u frontalne i parijetalne dijelove. Snažni podražaji dovode do snažnije aktivacije vidnih područja uz signale unaprijed i povratne signale unutar tih područja, kao i sinkronu aktivnost okcipitalnih i temporalnih područja; uz pridavanje pažnje takvom podražaju, ta aktivacija se širi i u parijetalne i frontalne dijelove kore. U užem kontekstu VRP-a (Trübtschek i sur., 2017), snažni podražaji dovode do "svjesnog" VRP-a koje je karakterizirano mogućnošću dekodiranja reprezentacija iz posteriornih senzornih područja; kod "nesvjesnog" VRP, takva aktivnost nestaje. Mehanizam koji bi mogao objasniti neuralno kodiranje nesvjesnih podražaja bez jasne aktivacije je prethodno opisano "neuralno tiho" VRP. U skladu s ovakvim opisom odnosa snage signala i neuralne aktivnosti, i bez pretpostavke o postojanju kategorija sublimalnih i supraliminalnih podražaja, možemo pretpostaviti kako (snažniji) neuralni signal uslijed percipiranja snažnijeg podražaja može u većoj mjeri ometati postojeći neuralni trag podražaja u VRP-u; slabiji neuralni signal uslijed slabih podražaja može eventualno narušiti reprezentacije u VRP-u ako je prikazan dok kvaliteta tih reprezentacija ovisi o senzornim područjima.

Ipak, VRP je više od pasivnog skladišta informacija te možemo pretpostaviti kako ono posjeduje mehanizam koji će smanjiti interferirajući utjecaj distraktora. Bonnefond i Jensen (2012) ispitivali su takav neuralni mehanizam supresije ometajućih podražaja. Koristeći Sternbergov zadatak, sudionicima su prikazivali slabe i snažne distraktore u fazi retencije. Bihevioralni podaci su pokazali kako je uradak mjeren vremenom reakcije, ali ne i točnosti detekcije, lošiji uz snažne distraktore. Tijekom obavljanja zadatka, sudionicima je EEG-om snimana aktivnost mozga, prvenstveno alpha valovi. Autori su pretpostavili kako prediktivnost snage signala (razdvojeni blokovi sa slabim i snažnim distraktorima) omogućava kontrolu alpha os-

cilacija mehanizmom *odozgo-prema-dolje*. Rezultati su pokazali kako pravovremena promjena amplitude i faze alpha signala u okcipito-temporalnom području smanjuje vrijeme odgovora u prisutnosti snažnog distraktora. Ova promjena tumači se kao supresija nadolazećeg distraktora, a zaključak ovog istraživanja jest kako efikasna obrana sadržaja radnog pamćenja počiva na mogućnosti kontrole *odozgo-prema-dolje* vidljivoj u alpha aktivnosti koja se tradicionalno smatra markerom VRP-a.

U prethodno opisanom istraživanju Dolcos i sur. (2007) pokazali su kako snažniji distraktori, tj. oni koji su sličniji materijalu koji se pamti, dovode do snažnije aktivacije prefrontalnih dijelova korteksa (mjerene fMR), kao posljedica kontrole i zaštite reprezentacija od distraktora. U skladu s tim istraživanjem je i nalaz Clapp i sur. (2010) koji su pokazali kako se ista ta prefrontalna područja uključuju nakon nestanka distraktora kojima je pridana pažnja, s ciljem održavanja i osvježavanja postojećih reprezentacija u posteriornim dijelovima. U situaciji ignoriranja distraktora, tj. situaciji slabih distraktora, komunikacija upravo tih anteriornih i posteriornih područja ne nestaje i omogućava uspješno obavljanje zadatka.

Nekoliko istraživanja bihevioralno prikupljene podatke pokušalo je objasniti neuralnim modelom koji pretpostavlja kako je preciznost dosjećanja posljedica većeg broja akcijskih potencijala koji su kodirali taj podražaj. Na primjer, Bays (2016b) i Tomić i Bays (2018) su pokazali kako preciznost dosjećanja raste sa snagom signala (manipuliranog kontrastom podražaja) te da neuralni model koji pretpostavlja kontinuirano dijeljenje ograničene količine akcijskih potencijala vrlo dobro objašnjava promjene u preciznosti pronađene u istraživanju. Drugim riječima, preciznije pamćenje podražaja s većim kontrastom (snažan podražaj), ova istraživanja uspjela su objasniti modelom koji pretpostavlja veću količinu akcijskih potencijala dodijeljenih tom podražaju. U skladu s ovim nalazima, nakon inicijalne raspodjele resursa na podražaje pohranjene u VRP, možemo pretpostaviti kako će slabi distraktori uzeti manju količinu resursa od svakog zapamćenog podražaja; snažniji distraktori zahtijevaju veću količinu resursa te njihovo kodiranje zahtjeva oduzimanje veće količine resursa inicijalno dodijeljene podražajima u VRP-u.

Iako relativno neistraženo područje, nekoliko istraživanja pokazalo je kako snažniji distraktori u pravilu ostvaruju snažniji utjecaj na reprezentacije pohranjene u VRP-u. Nadalje, i istraživanja provedena u kontekstu teorije detekcije signala kao i novija istraživanja VRP-a pokazuju kako su podražaji različite snage kodirani u neuralnom kodu različite snage. Na temelju tih spoznaja moguće je postaviti hipotezu kako snažniji distraktori dovode do snažnijih interferirajućih efekata u VRP-u.

1.5 Snaga reprezentacija u vidnom radnom pamćenju

Uz snagu distraktora, čimbenik koji određuje koliko će VRP uspješno obaviti zadatak u prisutnosti distraktora jest i sama snaga, tj. kvaliteta reprezentacije podražaja pohranjenog u VRP. Ako je reprezentacija nekog podražaja vrlo snažna, možemo očekivati da će ujedno biti i otpornija na distraktore, neovisno o njihovoj snazi. U istraživanjima VRP-a, neuralna kvaliteta reprezentacija posredno se interpretira preko preciznosti dosjećanja, pri čemu se preciznija dosjećanja (opravdana) opisuju kao posljedica kvalitetnijih reprezentacija. Najčešće istraživani faktor koji određuje preciznost dosjećanja jest broj podražaja koji se pamti, pri čemu porast broja podražaja koji se pamti dovodi do pada preciznosti kojom je svaki od njih upamćen (Bays, 2014). Vrijeme dostupno za kodiranje podražaja također predstavlja važnu odrednicu preciznosti, pri čemu kraće vrijeme kodiranja dovodi do nižih razina preciznosti i to neovisno o broju podražaja koji se pamti (Bays i sur., 2011). Nadalje, nakon inicijalne podjednake raspodjele resursa između svih podražaja, davanje prioriteta za dosjećanje jednom podražaju ili njegovo privremeno osvježavanje može dovesti do nejednake raspodjele resursa - u oba slučaja "povlašteni" podražaj (prioritetni ili osvježeni) bolje je zaštićen od preostalih podražaja (Souza i Oberauer, 2016). Konačno, podražaji kodirani jednakom količinom resursa imaju različitu snagu reprezentacije u različitim fazama obavljanja zadatka VRP-a; npr. faza kodiranja tradicionalno se smatra najosjetljivijom fazom jer se tijekom te faze dovršava stvaranje stabilne reprezentacije, zbog čega možemo pretpostaviti kako distraktori najsnažnije djeluju upravo u toj fazi (Xu, 2017).

1.6 Broj zapamćenih podražaja

Bihevioralna istraživanja

Najčešće demonstriran nalaz u području istraživanja VRP-a jest pad uratka s povećanjem broja podražaja koji se pamti. Neovisno o teorijskom uporištu, istraživanja pokazuju kako svako povećanje broja zapamćenih podražaja dovodi do otežane detekcije promjene i niže preciznosti dosjećanja (Brady i sur., 2011; Ma i sur., 2014). U istraživanju Bays i Husain (2008) zadatak sudionika u dva odvojena eksperimenta bio je ili da pamte lokacije podražaja ili njihove orijentacije, te u fazi dosjećanja odgovore koji je bio smjer pomaka lokacije ili smjer pomaka orijentacije prikazane na testnom ekranu u odnosu na zapamćeni podražaj (binarni odgovori lijevo-desno). Rezultati su pokazali kako se standardna devijacija kumulativne normalne distribucije koja je najbolje opisivala odnos točnih detekcija i veličine pomaka na testnom ekranu mijenja na predvidljiv način s porastom broja podražaja koji se pamti, najbolje opisanim potencijalnim odnosom ($\sigma \propto N^\lambda$). I druga istraživanja, koristeći zadatak kontinuirane procjene te izračun preciznosti na temelju distribucije pogrešaka dosjećanja pronašla su isti odnos, i to kada

su kao podražajni materijal korištene orijentacije (Bays, 2014; Mazyar i sur., 2012; Mazyar, van den Berg, Seilheimer i Ma, 2013; van den Berg i sur., 2012), boje (Bays i sur., 2009), te kada podražaji nisu prikazivani paralelno već sekvencijalno (Gorgoraptis i sur., 2011).

Ova istraživanja pokazuju kako broj podražaja koji se pamti određuje preciznost kojom će svaki od podražaja biti upamćen. Dodavanje svakog novog podražaja smanjuje količinu resursa koja se tom podražaju dodjeljuje i smanjuje preciznost njegovog dosjećanja. Pritom, promjena u količini resursa s jednog na dva upamćena objekta (100% na 50% resursa) veća je nego promjena s dva na tri objekta (50% na 33% resursa). U kontekstu prikazivanja distraktora možemo pretpostaviti kako svaki distraktor uzima određenu količinu resursa namijenjenu pohrani podražaja u VRP. Jedan scenarij jest da distraktori, neovisno o pohranjenom broju podražaja dobiju fiksni dio resursa. Alternativno, distraktori mogu dobivati količinu resursa slično na način na koji ih dobivaju reprezentacije u VRP-u - dodavanjem svakog novog podražaja, ukupna količina resursa se redistribuira podjednako na sve podražaje. U oba slučaja, promjena uslijed prikaza distraktora trebala bi biti veća uz pamćenje manjeg broja podražaja.

Ipak, pitanje utjecaja distraktora na reprezentacije različite preciznosti gotovo je neistraženo. Danas dominantna teorija koja povezuje ulogu broja zapamćenih podražaja i distraktore je Lavijina teorija kognitivnog opterećenja koja pretpostavlja kako obrada distraktora ovisi o količini dostupnih resursa nakon kodiranja informacija u VRP (Konstantinou, Beal, King i Lavie, 2014; Lavie, 2005; Lavie i Tsai, 1994). Prema ovoj teoriji distraktori će zaokupiti procese pažnje i biti obrađeni samo kada su zahtjevi za pohranu podražaja u VRP-u mali, npr. kada se pamti malen broj podražaja; kada se pamti veći broj podražaja, sav kognitivni kapacitet potrošen je na obavljanje primarnog zadatka, zbog čega se distraktori neće kognitivno obraditi. Iako je ova teorija usmjerena primarno na utjecaj broja zapamćenih podražaja na obradu distraktora, a ne na utjecaj distraktora na reprezentacije različite kvalitete (uslijed različitog broja zapamćenih podražaja), implicitno pretpostavlja kako distraktori mogu dovesti do interferirajućeg efekta samo kada VRP-e pohranjuje manji broj podražaja - u suprotnom, distraktori se neće niti obraditi jer pohranjeni podražaji troše sve dostupne resurse. Važno je napomenuti da su ova predviđanja isključivo vezana za pohranu u VRP - kada zadatak zahtjeva pamćenje verbalnog materijala čije zadržavanje zahtjeva aktivno ponavljanje (prema Lavie proces sličan kognitivnoj kontroli), veće opterećenje verbalnog radnog pamćenja dovest će do većeg procesiranja distraktora. Pretpostavke teorije opterećenja o ulozi opterećenja VRP-a vezane su uz istraživanja koja pokazuju kako vidna percepcija, kodiranje i zadržavanje podražaja u VRP-u počivaju na angažmanu istih neuralnih resursa (Serences i sur., 2009).

Prilikom eksperimentalne provjere ovog modela Konstantinou i sur. (2014) pretpostavili su kako kognitivno opterećenje prvenstveno određuje uključenost u sekundarni, manje važan zadatak pri čemu se uz visoko kognitivno opterećenje sudionici ne uključuju u obradu distraktora;

ako je kognitivno opterećenje nisko i omogućava dodatnu kognitivnu obradu, tada karakteristike tog sekundarnog zadatka određuju uradak u njemu. Kako bi provjerili tu pretpostavku, osmislili su eksperiment s niskim i visokim kognitivnim opterećenjem manipulirajući broj podražaja koji se pamti, te vidnom pretragom u kojoj su distraktirajući podražaji bili kongruentni ili nekongruentni podražaju kojeg se trebalo detektirati u toj vidnoj pretrazi. Produženo vrijeme odgovora u nekongruentnoj situaciji pokazuje kako sudionici ne uspijevaju ignorirati ometajuće, za zadatak nevažne podražaje, i indikator je da su ti distraktori bili obrađeni. Rezultati su pokazali kako sekundarni zadatak neovisno o kongruentnosti ne utječe na uradak u zadatku VRP-a. Ključno za testiranje predloženog modela, vrijeme reakcije uz nekongruentne distraktore bilo je sporije kada su sudionici pamtili manje boja, no takva razlika nije pronađena uz veće opterećenje. Na temelju ovog nalaza, autori su zaključili kako duže vrijeme reagiranja na distraktore uz manje kognitivno opterećenje odražava veću obradu distraktora.

U prethodno opisanom istraživanju Robison i sur. (2018) sudionicima su paralelno s različitim brojem podražaja za pamćenje (2 i 4) prikazivali i distraktore. U dva odvojena, ali gotovo identična eksperimenta, autori su dobili oprečne rezultate - u prvom eksperimentu, u usporedbi s kontrolnom situacijom, distraktori su imali veći utjecaj kada su sudionici pamtili 2 podražaja; u drugom eksperimentu, distraktori su imali veći utjecaj kada su sudionici pamtili 4 podražaja. Razlika između dva eksperimenta bila je u tome što su u prvom svi podražaji za pamćenje uvijek bili iste boje (crvene), kao i distraktori (plave), dok je u drugom eksperimentu na početku svake sekvence sudionicima naznačeno koje će boje biti podražaji za pamćenje (crvene ili plave). Ova razlika između dva eksperimenta teško može objasniti pronađene neusklađene nalaze.

Zaključno, istraživanja se do sada nisu bavila ispitivanjem uloge snage reprezentacija u VRP-u u njihovoj otpornosti na distraktore. Fokus istraživača je bio u većoj mjeri usmjeren na ulogu opterećenja VRP-a na obradu distraktora. Pri tom, teorijsko polazište tih istraživanja kompatibilno je s, do sada već osporenim, starijim teorijama utora. Fokus istraživanja koja su eksperimentalno manipulirala količinom podražaja koji se pamti i pritom od sudionika tražila da obavljaju sekundarni, distraktirajući zadatak, većinom nije bio usmjeren na otkrivanje utjecaja distraktora prilikom pamćenja različitog broja podražaja. Dostupni podaci iz tih radova pak ne daju konzistentne odgovore na ovo pitanje pri čemu neki radovi ne pronalaze razlike, dok neki pronalaze razlike u oba smjera - pamćenje manjeg broja podražaja nekad dovodi do veće, a nekad do manje interferencije. Iz svega navedenoga, jasno je da je potrebno sustavno istražiti utjecaj distraktora na reprezentacije VRP-a različite kvalitete.

Neuralna istraživanja

Efekt broja podražaja koji se pamti predstavlja ključni nalaz kojeg svi modeli VRP-a moraju moći objasniti. Prva istraživanja neuralne osnove VRP-a, motivirana primarno modelima utora, usmjeravala su se na područja u kojima je dostizan plato neuralne aktivnosti paralelno s bihevioralnim platom pamćenja (npr. Todd i Marois, 2004; Vogel i Machizawa, 2004; Xu i Chun, 2006; za test postojanja platoa neuralne aktivnosti u navedenim istraživanjima vidi Bays, 2018b). Neuralni modeli resursa u VRP-u (npr. Bays, 2014 i Z. Wei i sur., 2012) objašnjavaju pad preciznosti pamćenja podražaja s porastom broja podražaja mehanizmom globalne neuralne normalizacije (Carandini i Heeger, 2011). Prema ovom mehanizmu ukupna i fiksna količina neuralne aktivnosti (akcijskih potencijala) dijeli se na ukupnu količinu informacija koja se pamti. Na taj način, preciznost pamćenja pojedine informacije pada s porastom broja informacija koji se pamti. Ovaj mehanizam ključan je čimbenik i izvan VRP-a, npr. u modelima pažnje (Reynolds i Heeger, 2009). Važno je napomenuti kako je mehanizam normalizacije (Carandini i Heeger, 2011) originalno osmišljen kao lokalni mehanizam (obuhvaća manji broj regionalno bliskih neurona) dok u modelima VRP-a normalizacija je osmišljena kao mehanizam koji djeluje na sve zapamćene podražaje (sve populacije neurona). Nedavna istraživanja pronašla su dokaze za takav globalni mehanizam normalizacije (Mirpour i Bisley, 2012; Pastor-Bernier i Cisek, 2011). Specifično, psihofiziološka istraživanja pokazala su kako s porastom broja upamćenih podražaja dolazi do pada neuralne aktivnosti povezane s kodiranjem pojedinog podražaja (Balan, Oristaglio, Schneider i Gottlieb, 2008; Basso i Wurtz, 1998; Churchland, Kiani i Shadlen, 2008).

Sprague i sur. (2014) su od sudionika tražili da zapamte prostorne položaje nekoliko vidnih objekata za kasnije dosjećanje. Kada je uputom sudionicima rečeno da pamte samo jedan od dva prikazana podražaja, fMR snimke pokazale su snažnu neuralnu aktivnost koja je odgovarala lokaciji zapamćenog podražaja. U zadatku pamćenja dvije lokacije, opažena je aktivnost povezana s obje lokacije, no s amplitudom koja je bila znatno niža u odnosu na zadatak pamćenja jedne lokacije. Ovo istraživanje predstavlja iznimno snažnu potvrdu mehanizma globalne normalizacije u zadacima VRP-a. Važnu nadogradnju ovim nalazima ponudili su Emrich i sur. (2013). Oni su koristeći zadatak VRP-a i fMR snimanje mozga pronašli korelaciju pada preciznosti s porastom broja zapamćenih podražaja, i uspješnosti MVPA klasifikacije na temelju aktivnosti okcipitalnih područja. Ovaj nalaz replicirali su Gosseries i sur. (2018) dodatno podupirući hipotezu kako promjene neuralnog signala i preciznosti dosjećanja pojedinih podražaja zajednički prate promjene u broju podražaja koji se pamti. Ovdje opisana istraživanja nude snažne nalaze u prilog hipotezi kako resursi VRP-a odgovaraju ograničenoj količini neuralne aktivnosti koja se fleksibilno koristi za kodiranje svih dostupnih podražaja. Zajedno s neuralnim modelima koji na temelju istog mehanizma globalne normalizacije uspješno objašnjavaju

bihevioralni uradak u zadacima VRP-a, ova istraživanja podupiru danas dominantni pogled na VRP - s porastom broja podražaja koji se pamti, neuralni resursi dijele se kontinuirano na sve podražaje, što dovodi do pada preciznosti pamćenja svakog pojedinog podražaja.

Dva prethodno opisana scenarija djelovanja distraktora - oduzimanje fiksne i proporcionalne količine resursa - možemo prevesti u termine neuralnih modela koristeći se količinom neuralne aktivnosti dodijeljene distraktoru. Oduzimanje fiksne količine neuralne aktivnosti i pridavanje te aktivnosti distraktorima malo je vjerojatni scenarij jer je nepoznat neuralni mehanizam koji bi objasnio takvu vrstu alokacije resursa. S druge strane, ako su distraktori pod utjecajem globalne normalizacije kao i podražaji pohranjeni u VRP-u, količina neuralne aktivnosti pridana distraktorima bit će obrnuto proporcionalna ukupnom broju podražaja (za pamćenje i distraktora). Konačno, ako pretpostavimo kako percepcija distraktora rezultira stohastičkom neuralnom aktivnosti, odnosno povećanjem neuralnog šuma, podražaji kodirani većim brojem akcijskih potencijala (pamćenje kraćih nizova) bit će manje osjetljivi na dodavanje neuralnog šuma. Dodavanje i malih količina neuralnog šuma kod pamćenja većeg broja podražaja može rezultirati neuralnim signalom vezanim uz svaki podražaj koji se ne može razlikovati od signala te rezultira pogađanjem.

1.7 Vrijeme kodiranja

Bihevioralna istraživanja

Vrijeme kodiranja podražaja u VRP odnosi se na trajanje osjetnog podražaja kojeg osoba treba pohraniti u VRP. U eksperimentalnim uvjetima, vrijeme kodiranja odnosi se na trajanje ekspozicije podražaja za pamćenje na ekranu. Istraživanja koja ispituju ulogu dostupnog vremena kodiranja na uradak u zadatku VRP-a pokazuju kako se taj uradak poboljšava s produljenim vremenom kodiranja (Bays i sur., 2011; Bundesen, 1990; Cohen-Dallal, Fradkin i Pertzov, 2018; Vogel, Woodman i Luck, 2006). Ovaj nalaz objašnjava se ograničenom brzinom unosa informacija u vidni sustav, i jednako je konzistentan s dva vrlo različita mehanizma kodiranja: serijalnim (Hoffman, 1979) i paralelnim (Bunden, 1990). Odgovor na pitanje o točnoj prirodi kodiranja izvan je fokusa ovog rada, no paralelni model kodiranja ima nešto snažniju empirijsku potvrdu u području VRP-a (Dalmaijer, Manohar i Husain, 2018; Rideaux i Edwards, 2016; Shibuya i Bundesen, 1988). Točan mehanizam kodiranja nije ključan za ovo istraživanje no napomenimo kako se ovdje barem implicitno oslanjamo na paralelni model kodiranja. Uz pretpostavku o takvom kodiranju, povećanje preciznosti uz produženo vrijeme pretpostavlja kako u svakom trenutku svi kodirani podražaji imaju podjednaku količinu resursa. Serijalni model s druge strane pretpostavlja kako je uradak uz kraća vremena prosjek dosjećanja podražaja kojima

su pridani svi resursi i podražaja koji nisu dobili niti dio resursa.

Bays i sur. (2011) su sudionicima prikazivali različit broj podražaja (1, 2, 4 i 6) te pritom koristili različita vremena prikaza (od 25ms do 1000ms). Autori su pošli od hipoteze kako je kodiranje podražaja u VRP-u određeno dvama čimbenicima, brzinom unosa informacija u VRP i maksimalnom preciznosti, pri čemu su oba čimbenika ovisna o broju podražaja koji se pamti. Rezultati su potvrdili ovu hipotezu i pokazali kako se brzina kodiranja razlikuje ovisno o broju podražaja koji se pamti, te se može dobro opisati funkcijom obrnuto proporcionalnom broju podražaja (brzina $\propto 1/N$). Drugim riječima, manji broj podražaja ima brži porast u preciznosti dosjećanja sa svakim produženjem vremena kodiranja. Maksimalna preciznost u ovom istraživanju pratila je već opisani potencijalski odnos ($\sigma \propto N^\lambda$). Iz perspektive modela resursa, ovi nalazi pokazuju kako s produživanjem vremena kodiranja raste količina resursa pridana podražaju, pri čemu je maksimalna količina resursa koja se može pridati podražaju određena njihovim ukupnim brojem. Provjera pristajanja modela mješovitih distribucija podacima pokazala je kako vjerojatnost slučajnog odgovaranja, pogrešaka zamjene i preciznost točnih dosjećanja opada s porastom vremena kodiranja. Napomenimo kako ovi rezultati odbacuju strogo serijalni model kodiranja prema kojem su podražaji preneseni u VRP tek kada se potpuno obrade ("*sveili-ništa*"). Prema takvom modelu, očekivali bismo samo promjere u čestini pogađanja, ali ne i preciznosti ili čestini pogrešnih dosjećanja prikazanih ali netraženih podražaja.

Koliko je vremena potrebno da bi se određeni broj podražaja kodirao u VRP-u? Istraživanja su koristeći različite paradigme dolazila do različitih odgovora na ovo pitanje, predlažući gotovo sve od 50ms (Vogel i sur., 2006) do 500ms (Chun i Potter, 1995) po pojedinom podražaju. Nieuwenstein i Wyble (2014) su kombiniranjem paradigme za ispitivanje treptaja pažnje i maskiranja procijenili vrijeme konsolidacije podražaja u VRP-u. Fenomen treptaja pažnje pokazuje kako se od dva sukcesivna, vremenski blisko prikazana podražaja, drugi ne percipira jer je vidni sustav opterećen informacijama. Maskiranje počiva na pretpostavci kako od dva vremenski blisko prikazana podražaja, drugi podražaj prekida ulazak senzornih informacija prvog podražaja, pri čemu maska ponekad učini prvi podražaj "nevidljivim". Procjena vremena konsolidacije u ovom istraživanju iznosila je oko 1 sekunde. Napomenimo i kako vrijeme konsolidacije ima ponešto drugačije značenje od vremena kodiranja. Vrijeme kodiranja odgovara trajanju senzornog podraživanja, dok vrijeme konsolidacije obuhvaća i vrijeme nakon nestanka podražaja, a u kojem stabilna reprezentacija podražaja i dalje nije stvorena. U prethodno opisanom istraživanju Bays i sur. (2011) jedan od ključnih nalaza bio je da se plato preciznosti, neovisno o broju podražaja koji se pamti, dostiže kod ekspozicija od 200ms. Različite procjene ovih istraživanja pokazuju potrebu za sustavnim istraživanjem koje bi otkrilo izvore razlika u ovim procjenama. U istraživanjima prikazanim u ovoj disertaciji, korištena vremena kodiranja imaju svoje uporište u procjenama dobivenima u Bays i sur. (2011). Glavni razlog je taj što je

istraživačka paradigma u tom istraživanju najbližnja metodologiji korištenoj u našem istraživanju.

Neuralna istraživanja

Vremenska dinamika VRP-a često je istraživana tema u području VRP-a. Velik broj istraživanja ispituje kako se mijenja neuralna aktivnost tijekom faze zadržavanja (Gosseries i sur., 2018) te koji neuralni mehanizmi omogućavaju "pronalaženje" podražaja prilikom dosjećanja (Noorani i Carpenter, 2016). No podjednako važno pitanje je i neuralna osnova stvaranja reprezentacija ovisno o trajanju senzornog podraživanja kojeg treba pohraniti u VRP (Dehaene i sur., 2006; Lamme, 2003; Todd, Han, Harrison i Marois, 2011). Paralelno sa istraživanjima radnog pamćenja, istraživanja vidne percepcije tradicionalno su se usmjeravala na ulogu vremena prezentacije podražaja (Kaswan i Young, 1963), te se danas područje VRP-a u velikoj mjeri oslanja na spoznaje psihofizičkih istraživanja. Jedan dobro potvrđeni nalaz jest onaj kako vrijeme potrebno da bi se senzorni podražaji pretvorili u stabilnu reprezentaciju VRP-a ovisi o kompleksnosti tog podražaja pri čemu je za kodiranje kompleksnijih podražaja (npr. lica nasuprot orijentacijama) potrebno duže senzorno podraživanje (Curby i Gauthier, 2007; Eng, Chen i Jiang, 2005).

Način na koji VRP ovisi o dostupnom vremenu kodiranja možemo bolje razumjeti ako razmotrimo kako vidne informacije općenito putuju kroz neuralni vidni put. Vidna percepcija oslanja se na komunikaciju dijelova mozga duž vidnog puta - informacije pristigle u jedno područje (npr. V1) šalju se u područje koje slijedi u vidnoj hijerarhiji (V2) i ta komunikacija odvija se pomoću neuralnih signala unaprijed (engl. *feedforward signal*); paralelno s tim, viša vidna područja (npr. V2) šalju povratne informacije u niža područja (V1) pomoću povratnih neuralnih signala (engl. *feedback signal*). Obrada vidnih signala počiva na sukladnosti povratnih signala i neuralnih signala unaprijed, pri čemu svaka vrsta signala ima svoju vremensku dinamiku. Kada ne postoji sukladnost ove dvije vrste informacija, prekida se obrada jednog vidnog podražaja i započinje obrada podražaja kojeg nose signali unaprijed (vidi npr. Bullier, 2001; Lamme i Roelfsema, 2000). To znači da kodiranje vidnih informacija može biti prekinuto u bilo kojem dijelu vidnog puta, a ovisno o tome gdje je obrada informacija prekinuta bit će i senzorno iskustvo te informacije, odnosno kvaliteta njene pohrane. S produženim senzornim podraživanjem, sve veća količina vidnih informacija će biti prenesena u područja u kojima VRP pohranjuje podražaje, a povezani neuralni signal bit će distribuiran u raznim područjima mozga (Fuster i Bressler, 2012).

Neuralna istraživanja uspješnog kodiranja informacija uglavnom se baziraju na usporedbi neuralnih signala ovisno o uratku, odnosno, uspoređuju rane neuralne signale uspješnih i neuspješnih dosjećanja (Paller, Kutas i Mayes, 1987). Općeniti zaključak ovih istraživanja je kako je

aktivnost tijekom kodiranja viša za uspješno upamćene podražaje (Werkle-Bergner, Müller, Li i Lindenberger, 2006). Neuralna istraživanja koja su koristila paradigmu maskiranja kao način kontrole faze kodiranja pronašla su kako maska smanjuje neuralni signal povezan s podražajem prikazanim prije maske (Polat, Sterkin i Yehezkel, 2007). Haynes, Driver i Rees (2005) su manipulirajući vrijeme prikaza maske nakon ciljnog podražaja pokazali kako uradak u zadatku koji se poboljšavao s produženim vremenom kodiranja, korelira primarno s aktivnosti u višim vidnim područjima na način da je niža aktivnost tih područja prediktivna za lošiji uradak. I druga istraživanja identificirala su različita neuralna područja u kojima, ovisno o vrsti vidnog podražaja, dolazi do snažnije aktivnosti s produženim vremenom kodiranja, odnosno većim vremenskim razmakom između ciljnog podražaja i maske (M. F. Green i sur., 2005, 2009).

U terminima modela resursa, vrijeme ekspozicije podražaja povezano je s količinom resursa, tj. neuralne aktivnosti pridane tom podražaju (Bays i sur., 2011). Kratke ekspozicije podražaja ne omogućavaju potpuni prijenos vidnih informacija iz nižih vidnih područja u populaciju neurona zaduženu za pohranu. Djelomično kodiranje podražaja značit će i samo djelomično pridavanje dostupne količine resursa. U skladu s tim, može se krenuti od pretpostavke kako su reprezentacije kodirane duže vremena kvalitetnije jer im je pridana maksimalna moguća količina resursa, ograničena ukupnim brojem podražaja koji se pamti. Nadalje, u kontekstu osjetljivosti na distraktore, podražaji kodirani manjom količinom resursa potencijalno su osjetljiviji na distraktore, i u terminima preciznosti, ali i povezivanja objekata s njihovim prostornim razmještajem te mogućnosti "obrane" reprezentacija od intruzija nebitnih podražaja.

1.8 Prioritetnost i osvježavanje reprezentacija u pamćenju

Do sada je količina resursa pridana vidnim objektima opisivana primarno kao posljedica ukupnog broja podražaja koji se pamti. Pritom pretpostavljeno je kako svaki podražaj dobije otprilike podjednaku količinu resursa, te je podjednako važan za obavljanje zadatka. U svakodnevnim situacijama VRP rješava ponešto drugačiju vrstu problema od onih kakve nalazimo u eksperimentalnim istraživanjima. Ponekad pamćenje svih podražaja nije jednako važno za rješavanje nekog zadatka, te bi za adaptivno funkcioniranje bilo korisnije kada bi se resursi dodjeljivali u skladu s prioritetom koji pojedini podražaji imaju. Suprotno tome, ponekad pojedini podražaji iz okoline privuku više pažnje od ostalih podražaja jednako bitnih za obavljanje trenutnog zadatka. Uspijeva li VRP usklađivati ovakve različite informacije i distribuirati resurse ovisno o većem broju zahtjeva koje tipični zadaci postavljaju pred njega? Modeli resursa pretpostavljaju upravo takvu fleksibilnu raspodjelu resursa u skladu s važnosti podražaja (Ma i sur., 2014). Yoo, Klyszejko, Curtis i Ma (2018) su nedavno pokazali kako sudionici alociraju resurse u skladu s unaprijed najavljenom vjerojatnosti dosjećanja svakog podražaja. Međutim, što kada prioritet

informacija bude poznat tek nakon što su podražaji pohranjeni i nakon što senzorno podraživanje nestane? Kakvo je dosjećanje prioriteta podražaja u usporedbi s preostalim zapamćenim? Kakvo je dosjećanje istaknutih podražaja čiji prioritet za dosjećanje ostaje nepromijenjen? Istraživačka paradigma koja se koristi za ispitivanje fleksibilnog određivanja prioriteta u takvoj situaciji naziva se paradigma *signala unatrag* (engl. *retro-cues*) (Griffin i Nobre, 2003; Landman, Spekreijse i Lamme, 2003). U toj paradigmi, sudionici pamte određeni broj podražaja za kasnije dosjećanje. Tijekom faze zadržavanja, prikazuje im se znak koji ukazuje koji će se od prikazanih podražaja najvjerojatnije tražiti za dosjećanje. Najčešće se kao znak koristi prostorni položaj podražaja, no istraživanja su pokazala i kako bilo koje drugo sekundarno obilježje podražaja koje može poslužiti za identifikaciju podražaja, poput boje ili oblika, može biti informativan signal unatrag (Li i Saiki, 2015; Pertzov, Bays, Joseph i Husain, 2013).

Bihevioralna istraživanja

Nalazi istraživanja koja koriste paradigmu signala unatrag pokazuju kako su dosjećanja signaliziranog podražaja točnija i brža (npr. Souza, Rerko i Oberauer, 2014). Iako je ovaj efekt repliciran mnogo puta, točan mehanizam djelovanja signala unatrag, tj. zašto je snaga signaliziranog podražaja veća, nije sasvim jasan. Iako je jasno kako djelovanje signala počiva na *odozgo-prema-dolje* kognitivnim procesima, istraživanja za sada nisu dokazala koji konkretan proces bi mogao objasniti generalni nalaz o koristi signala za dosjećanje. Neke od specifičnih hipoteza su kako signal unatrag usporava osipanje pamćenja (Pertzov i sur., 2013, 2017), dovodi do prvenstva usporedbe s testnim ekranom kod dosjećanja (Asthle, Summerfield, Griffin i Nobre, 2012; Makovski, Sussman i Jiang, 2008; Matsukura, Luck i Vecera, 2007), izbacuje nesignalizirane podražaje iz VRP-a (Souza, Rerko i Oberauer, 2014; Williams, Hong, Kang, Carlisle i Woodman, 2013), ubrzava akumulaciju informacija signaliziranog podražaja kod dosjećanja (Nobre, 2008; Souza, Rerko i Oberauer, 2016), osnažuje signalizirani podražaj (Rerko, Souza i Oberauer, 2014; Souza, Rerko, Lin i Oberauer, 2014; Souza, Rerko i Oberauer, 2015), te sprječava interferirajući utjecaj drugih podražaja na signalizirani (Hollingworth i Maxcey-Richard, 2013; Makovski i Pertzov, 2015) (za detaljan pregled hipoteza i postojećih istraživanja vidi Souza i Oberauer, 2016). Važno je imati na umu kako ovi mehanizmi nisu međusobno suprotni te da su neki od njih primjenjivi samo u određenim vrstama zadataka. Na primjer, osnaživanje reprezentacije može dovesti do sporijeg osipanja ili zaštite od interferencije od strane drugih zapamćenih podražaja.

U kontekstu ranijih verzija modela resursa, smatra se kako davanje prioriteta podražaju korištenjem signala unatrag dovodi do redistribucije već raspodijeljenih resursa čime se veća količina resursa pridaje signaliziranom podražaju. Bays i sur. (2011) sudionicima su prikazivali

signale unatrag koji su bili prediktivni za dosjećanje u 2/3 sekvenci, a zatim varirali vrijeme između nestanka signala unatrag i dosjećanja. Rezultati su pokazali preciznije dosjećanje signaliziranog podražaja kada je razmak signala i dosjećanja bio 200ms i duži. Ovaj nalaz pokazuje kako sam proces redistribucije zahtjeva određeno vrijeme. U istom istraživanju autori su provjerili kakva je uloga neinformativnih signala, odnosno signala koji ukupno gledano nisu prediktivni za dosjećanje (npr. kod pamćenja 2 podražaja, predviđaju koji će element biti tražen za dosjećanje u samo 50% sekvenci). Ovakva eksperimentalna manipulacija odgovara svakodnevnim situacijama obavljanja zadatka u kojima okolinski signali istaknu jedan od podražaja bitnih za obavljanje zadatka (mehanizam *odozdo-prema-gore*) pri čemu svi podražaji ostaju jednako relevantni za obavljanje zadatka. Usporedbom sekvenci na kojima je takav signal bio prediktivan s preostalim sekvencama kada signal nije bio prediktivan, pronašli su vrlo specifičan benefit za dosjećanje - sudionici su se signaliziranog podražaja dosjećali bolje samo kada je dosjećanje uslijedilo vrlo brzo nakon signala. Drugim riječima, sudionici su spontano redistribuirali resurse signaliziranom podražaju, ali ih ubrzo nakon toga ponovno alocirali u skladu s njihovom (jednakom) važnosti za zadatak.

Ovo i slična istraživanja otvorila su važno pitanje vezano uz djelovanje signala unatrag - kakvo je djelovanje signala ovisno o njegovoj prediktivnosti? Prva istraživanja koristila su 100% prediktivne signale, te su sudionici mogli sve resurse dodijeliti signaliziranom podražaju. No, mogu li sudionici fleksibilno raspodijeliti resurse ovisno o prediktivnosti signala? Günseli, van Moorselaar, Meeter i Olivers (2015) sudionicima su na svakoj sekvenci prikazivali četiri orijentacije koje su trebali zapamtiti za kasnije dosjećanje. Tijekom faze zadržavanja u nekim sekvencama signalizirali su koja će se od prikazanih orijentacija najvjerojatnije tražiti za dosjećanje. Pritom, ključna manipulacija bila je u ukupnoj prediktivnosti tih signala. U situaciji visoke prediktivnosti, signal je bio prediktivan u 80% sekvenci, dok je u situaciji niske prediktivnosti signal bio prediktivan samo u 50% sekvenci. Drugim riječima, svaki od preostalih, nesignaliziranih podražaja mogao je biti tražen za dosjećanje u otprilike 6% odnosno 16% sekvenci. U skladu s prethodnim istraživanjima, kada je signal bio prediktivan, dosjećanje je bilo preciznije i vjerojatnost točnog dosjećanja bila je viša u usporedbi s kontrolnom situacijom. Kada signal nije bio prediktivan, pad preciznosti i vjerojatnosti dosjećanja u usporedbi s kontrolnom situacijom, pronađen je samo u situaciji visoko prediktivnih signala (80%). Drugim riječima, dosjećanje nesignaliziranih podražaja ovisilo je o vjerojatnosti njihovog traženja za dosjećanje - kada je ta vjerojatnost bila iznimno niska, sudionici su oduzimali resurse tim podražajima; kada ta vjerojatnost nije bila bezazlena, sudionici su ih pamtali do kraja sekvence (vidi Günseli i sur., 2018 za slične nalaze).

Bogat skup nalaza o ulozi signala unatrag u VRP-u, a posebno njihovoj pouzdanosti, omogućava formiranje pretpostavki kako bi se ispitala uloga privremenog i trajnog osnaživanja već

upamćenih podražaja u VRP-u. Konkretno, može se pretpostaviti kako visoko pouzdani signali unatrag dovode do davanja prioriteta podražaju za dosjećanje - ovaj proces smatramo odrazom procesa *odozgo-prema-dolje* koji trajno ističe jedan podražaj kao najbitniji za obavljanje trenutnog zadatka. Posljedice takvih visoko pouzdanih signala na prioritetni podražaj mogu se odraziti u znatno preciznijem dosjećanju u odnosu na podražaje koji nisu označeni kao prioritetni za dosjećanje. Nadalje, nisko pouzdane signale, odnosno one koji ističu jedan od podražaja tijekom faze zadržavanja, ali ne mijenjaju relevantnost tog podražaja za dosjećanje smatraju se odrazom procesa *odozdo-prema-dolje* koji privremeno osnažuje reprezentaciju pohranjenog podražaja.

Potonji proces u literaturi poznat je i kao proces osvježavanja reprezentacija (Rerko i Oberauer, 2013; Souza i sur., 2015). Tipično korištena paradigma za ispitivanje osvježavanja sudionicima istakne jedan od prethodno zapamćenih podražaja uz uputu 'Pomislite na ovaj podražaj'. Ova i slična istraživanja pokazuju kako je dosjećanje osvježenog podražaja preciznije u usporedbi s dosjećanjima u istom zadatku kada se osvježavanje ne koristi, kao i u usporedbi s neosvježenim podražajima. Posebno je zanimljiv nalaz koji pokazuje kako frekvencija osvježavanja utječe na preciznost dosjećanja i to na način da što je više puta određeni podražaj signaliziran tijekom faze zadržavanja, to je bolje njegovo dosjećanje (Rerko i Oberauer, 2013; Souza i sur., 2015).

Prethodno je spomenuto kako neki autori razmatraju korisnost signala unatrag prvenstveno u terminima obrane signaliziranog podražaja od interferencije. Mehanizam te obrane može počivati na pridavanju više resursa signaliziranom podražaju ili oduzimanju resursa nesignaliziranim podražajima. Istraživanja su uspješno demonstrirala kako signal unatrag štiti signalizirani podražaj od interferencije irelevantnim podražajem (maskom) tijekom retencije (Makovski i Jiang, 2007; van Moorselaar, Gunseli, Theeuwes i Olivers, 2015). Snažniji dokaz u prilog ovoj hipotezi daju istraživanja koja su koristila neku vrstu umetnutog zadatka, stavljajući veći izazov pred VRP. Makovski i Pertzov (2015) pronašli su usporediv uradak za signalizirane podražaje sa i bez sekundarnog zadatka; kod izostanka signala uradak je bio znatno lošiji u prisustvu dodatnog zadatka. Ovo istraživanje demonstriralo je kako su signalizirani podražaji zaštićeni od interferencije dok nesignalizirani podražaji pokazuju očekivan pad uratka uslijed ometajućeg zadatka (za slične nalaze vidi Hollingworth i Maxcey-Richard, 2013 i Rerko, Souza i Oberauer, 2014).

Neuralna istraživanja

Neuralna istraživanja prioriteta podražaja u VRP-u pokazuju kako neuralna aktivnost (amplituda i obrazac koji se koristi u MVPA) povezana s nesignaliziranim podražajem pada na razinu

stanja mirovanja, dok aktivnost povezana sa signaliziranim podražajem ostaje mjerljiva i prediktivna za taj podražaj (LaRocque i sur., 2013; Lewis-Peacock i sur., 2012). Nadalje, kada se u zadatku VRP-a prvotno nesignalizirani podražaj kod višestrukog dosjećanja naknadno signalizira, dolazi do ponovne pojave neuralne aktivnosti povezane s tim podražajem i uratka u zadatku koji je značajno bolji od slučaja (LaRocque i sur., 2017; Lewis-Peacock i sur., 2012; Sprague i sur., 2016). Uzevši ove nalaze zajedno, neki autori su predložili kako ovakva dinamika odražava privremeno izbacivanje informacija iz VRP-a pri čemu kasnije dozivanje tih reprezentacija podražaja ovisi o mogućnosti njihovog povezivanja sa znanjem u dugoročnom paćenju (Lewis-Peacock, Kessler i Oberauer, 2018). Također, ova istraživanja motivirala su pojavu drugih mehanizama pohrane, poput ranije spomenute hipoteze o "tihom pohrani" VRP-a prema kojoj podražaji izvan fokusa pažnje nisu kodirani u stalnoj aktivnosti populacije neurona, već u kratkotrajnim promjenama u sinaptičkoj plastičnosti (Rose i sur., 2016; M. G. Stokes, 2015; Wolff, Jochim, Akyürek i Stokes, 2017). Ako uistinu postoje, različiti načini pohrane signaliziranih i nesignaliziranih podražaja mogli bi odrediti i utjecaj distraktora na svaki od tih podražaja.

Nadalje, interpretacija putem "tihog kodiranja" predstavlja izazov za modele resursa prema kojima resursi predstavljaju opazivu neuralnu aktivnost, pri čemu je nestanak akcijskih potencijala analogan nestanku resursa koji se bez novog senzornog podraživanja ne mogu ponovno pojaviti. Prema informacijskoj teoriji, nakon što neki sadržaj uđe u informacijski kanal (npr. mozak), i nestane u svom originalnom obliku, nikakvo naknadno procesiranje ne može povećati količinu informacija o tom sadržaju (Shannon, 1948). Imajući to na umu, bilo koji mehanizam koji bi nakon nestanka senzornog podraživanja doveo do osnaživanja neuralne aktivnosti vezane uz signalizirani podražaj (npr. neka vrsta multiplikativne funkcije), nužno bi povećao i količinu neuralnog šuma, ne mijenjajući ukupnu količinu informacija o podražaju. Ukratko, jednom kada se podražaj kodira neuralnom aktivnosti, prema novijim formulacijama modela resursa, taj podražaj može samo gubiti na kvaliteti reprezentacije.

Međutim, tipično opaženi oporavak kvalitete reprezentacije uslijed dodatnog signaliziranja (E. F. Ester, Nouri i Rodriguez, 2018) može biti posljedica distribuirane, a ne strogo lokalne, pohrane podražaja pomoću opazive neuralne aktivnosti kakvu pretpostavljaju modeli resursa. Christophel i sur. (2018) su koristili tipičan zadatak radnog pamćenja ali s dvostrukim signaliziranjem i dosjećanjem. U ovoj paradigmi prvi dio zadatka identičan je klasičnoj paradigmi signaliziranja unatrag, nakon čega slijedi drugi signal (koji može biti isti ili drugačiji od prvog) i drugo dosjećanje. Snimajući neuralnu aktivnost fMR autori su pokušali povezati neuralnu aktivnost tijekom zadatka sa svakim od dva zapamćena podražaja, i to kada su oni bili i kada nisu bili signalizirani. Umjesto pristupa klasifikacije korištenjem MVPA autori su u ovom istraživanju primijenili osjetljiviju analizu namijenjenu kontinuiranim zavisnim varijablama (za

detalje vidi Allefeld i Haynes, 2014). Analiza ranih vidnih područja (V1–V4) pronašla je, u skladu s prethodnim istraživanjima, kako ta područja reprezentiraju samo signalizirane podražaje. Važan nalaz koji prethodno nije demonstriran bio je kako su podražaji, neovisno o tome jesu li u tom trenutku signalizirani ili ne, reprezentirani u intraparietalnom području (IPS) i prednjem očnom području (FEF). Ovo istraživanje pokazuje kako davanje prioriteta reprezentaciji ne podrazumijeva njeno prebacivanje iz opazivog, aktivnog koda u "tiho kodiranje". Čini se kako mozak pohranjuje podražaje različitog prioriteta regrutirajući neka područja isključivo za trenutno najvažnije informacije, dok su preostale informacije stabilno distribuirane u drugim područjima.

Do sada opisana istraživanja objasnila su neuralnu pozadinu promjene prioriteta podražaja unutar jedne sekvence. No koja je neuralna pozadina klasičnog nalaza istraživanja signala unatrag, onog o preciznijem dosjećanju uslijed signala u odnosu na kontrolnu situaciju bez signala? Podsjetimo, modeli resursa prethodno su objašnjavali ovu razliku u terminima redistribucije resursa na način da signalizirani podražaj dobije veću količinu resursa u odnosu na nesignalizirani (u kontrolnoj situaciji svi podražaji dobiju podjednaku količinu resursa). Prethodno spomenuto ograničenje proizašlo iz informacijske teorije (Shannon, 1948) govori kako se resursi, nakon što su raspodijeljeni, ne mogu povećavati. Ovo ograničenje baca drugačije svjetlo na klasične nalaze istraživanja signala unatrag - jedini način na koji dosjećanje uslijed signala može biti bolje u odnosu na kontrolna dosjećanja jest ako signal štiti od procesa zaboravljanja. Bays i Taylor (2018) nedavno su provjerili pristajanje neuralnog modela VRP-a podacima iz 8 eksperimenata u kojima je korištena paradigma signaliziranja unatrag i zadatak kontinuirane procjene. Očekivano, u usporedbi s uratkom u kontrolnim skupinama, signaliziranje podražaja unatrag dovelo je do razlike u količini neuralne aktivnosti pridane signaliziranom podražaju, bez promjene u širini udešenosti neurona. Autori su interpretirali ove rezultate u skladu s upravo opisanom logikom. Veća neuralna aktivnost povezana sa signaliziranim podražajem zapravo je odraz bržeg zaboravljanja (gubitka resursa) opaženog u kontrolnim situacijama.

Koliko su podražaji kojima je dan prioritet za dosjećanje osjetljivi na interferirajući utjecaj distraktora? Intuitivna pretpostavka modela resursa jest da prioritetni i osvježeni podražaji imaju stabilniju reprezentaciju, i to kao posljedicu zaštite od osipanja ili interferencije od drugih podražaja u pamćenju. U skladu s tim, možemo pretpostaviti i kako su prioritetni podražaji u VRP-u (visoko prediktivan signal) kao i osvježeni podražaji (neprediktivan signal) manje osjetljivi na utjecaj distraktora. Važno pitanje je kakve su posljedice distraktora za podražaje koji nisu prioritetni ili osvježeni. Jedna mogućnost jest da su takvi podražaji osjetljiviji na distraktore, pretpostavljeno kao posljedica usmjeravanja zaštitnih mehanizama na prioritetne ili osvježene podražaje. Nadalje moguće je da signaliziranje određuje mjesto pohrane podražaja pri čemu nesignalizirani podražaji, tj. oni koji nisu prioritetni ili osvježeni, budu pohranjeni u

područjima u kojima perceptivni distraktori ne utječu kvalitetu pohrane. Konačno, najvjerojatniji ishod jest da neprioritetni i neosvježeni podražaji pokažu različitu osjetljivost na distraktore. Konkretno, pohrana podražaja koji nisu prioritetni za dosjećanje vjerojatno se odvija u dijelovima mozga koji nisu pod utjecajem distraktora te će time biti manje osjetljivi na njih; ključno, neisticanje tih podražaja kao prioritetnih moglo bi imati detrimentalan utjecaj na preciznost neovisno o distraktorima. Neosvježeni podražaji s druge strane vjerojatno se pohranjuju u istim područjima kao i osvježeni podražaji, no privremeno osvježavanje drugih podražaja moglo bi neosvježene podražaje učiniti osjetljivijima na distraktore.

1.9 Faza obrade

Do sada opisivana istraživanja snagu reprezentacija u VRP-u izjednačavala su s količinom resursa pridanih tim reprezentacijama. Pretpostavka u pozadini ovih istraživanja jest da će reprezentacije podražaja kodiranih većom količinom resursa biti manje narušene unošenjem neuralnog šuma uslijed prezentacije distraktora. Alternativno, osjetljivost reprezentacija na distraktore može varirati ovisno o fazi obrade podražaja. Specifično, reprezentacije u VRP-u mogu biti različito osjetljive u fazi kodiranja, zadržavanja i dosjećanja. Vremenske karakteristike otpornosti reprezentacija u VRP-u predstavljaju važno pitanje o radu VRP-a. Ovaj problem primarno je vezan uz interakciju neuralnih područja koja pohranjuju reprezentacije VRP-a i područja koja obrađuju distraktore. Ako su distraktori vidni podražaji koji zahtijevaju (samo) perceptivnu obradu, tada ih primarno obrađuju senzorna područja. U tom slučaju, interferirajući efekt opazit ćemo samo u fazama kada i VRP počiva na tim senzornim područjima. U prvom dijelu ovog poglavlja dan je pregled bihevioralnih istraživanja koja nam mogu dati odgovor na pitanje o osjetljivosti VRP-a na distraktore tijekom različitih faza. Nakon toga, pažnja je usmjerena na istraživanja koja su primarno ispitivala neuralnu osnovu VRP-a i obrade distraktora tijekom različitih faza obavljanja zadatka VRP-a.

Bihevioralna istraživanja

Istraživanja prikazana u poglavlju o vremenu kodiranja pokazuju kako je faza kodiranja VRP-a posebno osjetljiva - kvaliteta reprezentacija u VRP-u pada ako nešto omete ovu fazu, poput skraćivanja trajanja senzornog podražaja koji se pamti. Nadalje, Vogel i sur. (2006) su pokazali kako prikazivanje maskirajućeg podražaja prije, ali ne i nakon završetka konsolidacije, utječe na sposobnost detekcije promjene u tipičnom zadatku VRP-a. Iako je djelotvornost maske u opisanom istraživanju korištena kao indikator trajanja konsolidacije zbog čega su zaključci tog istraživanja donekle cirkularni, važan nalaz je kako prikazivanje novih vidnih podražaja s

vremenskim odmakom od završetka konsolidacije ne dovodi do pada uratka u zadatku. Do sličnog zaključka kao Vogel i sur. (2006) došli su i Pasternak i Zaksas (2003). Istraživanje Wang i sur. (2018) pokazalo je kako čak i prekratki vremenski razmak između faza pamćenja i dosjećanja može dovesti do lošijeg uratka, pretpostavljeno uslijed interferencije testnog ekrana prije dovršetka konsolidacije. I druga istraživanja pronašla su interferirajući efekt prikazujući distraktore paralelno s podražajima koji su se pamtili (vidi npr. Shipstead, Lindsey, Marshall i Engle (2014); Vissers i sur. (2017); vidi Jeong i Xu (2013) za suprotne nalaze). Navedena istraživanja pokazuju kako je rana faza obrade u VRP-u osjetljiva na ometajuće podražaje.

van Ede, Chekroud i sur. (2018) su u ranije opisanom istraživanju nakon prezentacije podražaja za pamćenje sudionicima prikazali i distraktirajući podražaj, i to s razmakom od 20ms, 100ms ili 200ms. Važno, i podražaj za pamćenje i distraktor imali su istu vidnu kvalitetu, i to orijentaciju. Rezultati su pokazali kako pogreška dosjećanja opada s povećanjem vremenskog razmaka između podražaja koji se pamtio i distraktora. Pritom, pogreške dosjećanja bile su značajno veće nego u kontrolnoj situaciji i kada je distraktor prikazivan 200ms nakon podražaja za pamćenje. Iako je 200ms relativno kratak razmak i vjerojatno ne izlazi izvan vremena konsolidacije, ovo istraživanje pokazuje kako povećanje vremenskog razmaka između upamćivanja podražaja i prikaza distraktora dovodi do pada u veličini interferencije.

Slično istraživanje proveli su van Lamsweerde i Johnson (2017) koristeći zadatak detekcije promjene i kontinuirane procjene, te maskirajući podražaj kao metodu izazivanja interferencije. Ključno, prikaz maske uslijedilo je odmah nakon nestanka niza za pamćenje (0ms) te 100ms i 200ms. U zadatku detekcije promjene pronađen je efekt maske prikazane 0ms i 100ms, ali ne i 200ms nakon nestanka podražaja za pamćenje, pri čemu je točnost detekcije bila niža uz neposredno prikazivanje maske. U zadatku kontinuirane procjene, pogreške dosjećanja pokazale su isti obrazac, s većim pogreškama uz masku prikazanu 0ms i 100ms nakon podražaja za pamćenje, ali ne i 200ms. Analiza modelom mješovite distribucije pokazala je kako je izvor povećanja pogreške dosjećanja u porastu proporcije pogađanja. Drugim riječima, čini se kako je "maska" izbrisala reprezentaciju pohranjenu u VRP.

Prikazivanje distraktora u fazi zadržavanja također dovodi do interferirajućeg efekta. Većina istraživanja opisana u poglavlju o interferenciji koristila su prikaze distraktora i do nekoliko sekundi nakon prikaza podražaja za pamćenje (vidi npr. Fallon i sur., 2018; Nemes i sur., 2011; Rademaker i sur., 2015). Konstantinou i sur. (2014) su provjeravali ulogu prikazivanja distraktora u fazi kodiranja i zadržavanja. U već opisanom istraživanju, sudionici su uz pamćenje obojenih kvadrata obavljali zadatak vidnog pretraživanja koji je mogao dovesti do interferirajućih efekata u zadatku VRP-a. Procjene točnosti detekcije u zadatku VRP-a nisu se razlikovale između situacija prikaza distraktora tijekom kodiranja i tijekom zadržavanja. Autori su pronašli duže vrijeme vidne pretrage kada su ju sudionici obavljali u fazi zadržavanja. Ovaj nalaz upu-

čuje kako je obrada distraktora u kasnijoj fazi VRP-a trajnija, te bi distraktori prikazani tada posljedično mogli imati veći utjecaj. Slično tome McNab i sur. (2015) su pronašli kako prikazivanje distraktora u fazi zadržavanja dovodi do veće interferencije nego prikazivanje u fazi kodiranja, te da je taj efekt stabilan tijekom odrasle dobi. U ovom istraživanju, vrijeme retencije je trajalo 1 sekundu te su distraktori bili prisutni tijekom cijele retencije, tj. od nestanka podražaja za pamćenje do davanja odgovora. Drugim riječima, McNab i sur. (2015) su u situaciji interferencije u fazi zadržavanja vjerojatno obuhvatili i kasni period kodiranja i konsolidacije.

Konačno, na temelju nalaza nekih istraživanja možemo pretpostaviti i kako bi faza dosjećanja mogla biti podložna interferirajućim efektima. Istraživanja su pokazala kako u fazi dosjećanja dolazi do povećane aktivnosti senzornih područja (Xu i Chun, 2006), zbog čega je moguće pretpostaviti kako "dekodiranje" zapamćenih reprezentacija počiva na istim područjima koje aktiviraju perceptivni distraktori. To je ujedno i temeljna pretpostavka dominantne teorije dosjećanja iz dugoročnog pamćenja, teorije ponovnog kortikalnog uspostavljanja (eng. *cortical reinstatement theory*; Rugg, Johnson, Park i Uncapher, 2008). Ako dosjećanje i u VRP-u počiva na aktivnosti senzornih područja, prikaz distraktora u toj fazi mogao bi dovesti do sličnog interferirajućih efekta kao i u fazi kodiranja. U kontekstu hipoteze senzornog regrutiranja (engl. *sensory recruitment hypothesis*), ako se podražaji VRP-a doista pohranjuju u senzornim područjima, važno je pokazati kako su reprezentacije jednako osjetljive na distraktore u svim fazama obrade. Istraživanja se često usmjeravaju ili na fazu kodiranja ili na fazu zadržavanja prilikom ispitivanja distraktora te na temelju (ne)postojanja razlike u interferenciji između te dvije faze donose zaključke o neuralnoj osnovi VRP. Potencijalan, iako malo vjerojatan, scenarij je onaj u kojem su faze kodiranja i zadržavanja osjetljive na distraktore, dok faza dosjećanja nije. Ispitivanjem prve dvije faze obrade moglo bi se zaključiti kako se pohrana VRP odvija u senzornim područjima, no uključivanjem posljednje faze, takva interpretacija ne bi bila opravdana.

Neuralna istraživanja

Već je rečeno kako su vremenske karakteristike otpornosti reprezentacija u VRP-u najviše pažnje pridobile su u kontekstu istraživanja neuralnih osnova VRP-a. Već ranije spomenute dvije široke skupine hipoteza pretpostavljaju kako se pohrana sadržaja u VRP-u odvija dominantno u senzornim (Awh i Jonides, 2001; Emrich, 2015; Pasternak, Lui i Spinelli, 2015; Sreenivasan, Curtis i D'Esposito, 2014) odnosno prefrontalnim (Durstewitz, Seamans i Sejnowski, 2000; Mendoza-Halliday, Torres i Martinez-Trujillo, 2015; Riley i Constantinidis, 2016) i parijetalnim (Xu i Jeong, 2015) dijelovima mozga. Prema hipotezi senzornog regrutiranja reprezentacije u VRP-u u svim fazama obrade počivaju na aktivnosti vidnih senzornih područja (S. A. Harrison i Tong, 2009). Svaki dodatni angažman senzornih područja u bilo kojoj fazi obrade trebao bi

rezultirati istim, nepovoljnim efektima. Alternativno, različite faze obrade mogu počivati na neuralnoj aktivnosti različitih mozgovnih područja (Bettencourt i Xu, 2016). Prema ovoj hipotezi, VRP bi na distraktore trebalo biti osjetljivo samo u fazi pohrane, no ne i nakon što se senzorne informacije prenesu i konsolidiraju u VRP-u.

U ranije opisanom istraživanju van Lamsweerde i Johnson (2017), autori su u trećem provedenom eksperimentu kao metodu interferencije koristili TMS podraživanje okcipitalnog korteksa. Kao i kod prikaza maske i zadavanje TMS pulseva uslijedilo je neposredno (0ms) te 100ms i 200ms nakon niza za pamćenje. U ovom eksperimentu, pronađen je samo značajan porast proporcije pogađanja uz neposredno TMS podraživanje (0ms). Zanimljivo, pronađen je pad u proporciji pogrešaka zamjene uz sva tri vremena TMS podraživanja, rezultat koji sugerira poboljšano povezivanje kvalitete koja se pamtila (boja) i lokacija na kojoj su te boje prikazane. van de Ven, Jacobs i Sack (2012) su koristeći zadatak detekcije promjene sudionicima zadavali TMS podražaje preko okcipitalnog režnja (eksperiment 2) ili su im prikazivali maskirajući podražaj (eksperiment 3), u oba slučaja 100ms, 200ms ili 400ms nakon kraja prezentacije podražaja za pamćenje. Rezultati dobiveni ovim dvjema manipulacijama pokazali su pad u točnosti detekcije samo 200ms nakon prikazivanja podražaja za pamćenje. Autori su interpretirali ove rezultate kao nalaze u prilog pretpostavci kako vidna osjetna područja imaju ulogu u kodiranju i konsolidaciji (200ms) podražaja, ali ne i daljnjoj pohrani (400ms). TMS podraživanje vjerojatno je djelovao samo na povratni neuralni signal (200ms), ali ne i na signal unaprijed (100ms) čime nije pronađen utjecaj TMS podražaja u najranijoj fazi kodiranja. Važna razlika između dva opisana istraživanja jest i korišteni podražajni materijal: van Lamsweerde i Johnson (2017) su koristili boje, a van de Ven i sur. (2012) apstraktne oblike. Rademaker, van de Ven, Tong i Sack (2017) su od sudionika tražila da zapamte četiri orijentacije za kasniju reprodukciju, te im zadavali TMS podražaje preko okcipitalnog područja. I ovo istraživanje pokazalo je porast proporcije pogađanja kada je TMS zadan rano (0ms nakon nestanka podražaja za pamćenje) u odnosu na kasno zadavanje (900ms). Koristeći samo rano TMS podraživanje, neposredno nakon nestanka podražaja za pamćenje, Cattaneo, Vecchi, Pascual-Leone i Silvanto (2009) su pronašli smanjenu točnost detekcije i porast u vremenima reakcija kada je TMS bio zadan preko okcipitalnih područja u odnosu na situaciju bez TMS i TMS preko vertexa (vrh lubanje).

Nedavna istraživanja sugeriraju kako TMS podraživanje smanjuje snagu signala podražaja koji se pamti (Harris i sur., 2008), nalaz koji je suprotan pretpostavci o povećanju neuralnog šuma TMS signalima (Abrahamyan, Clifford, Arabzadeh i Harris, 2011; Schwarzkopf, Silvanto i Rees, 2011). U skladu s tim su i rezultati ovdje navedenih istraživanja koja su pronašla najpouzdanije promjene u proporciji točnih dosjećanja (tj. pogađanja). Zajedno, ova istraživanja pružaju snažne nalaze u prilog hipotezi kako ometajući signali mogu narušiti reprezentacije u VRP-u samo ako se pojave u ranim fazama obrade, dok kodiranje i konsolidacija podražaja još

nije dovršena. Nakon toga, u skladu s hipotezom o PPS i IPS kao mjestu pohrane reprezentacija VRP-a, angažman senzornih područja ne dovodi do pada uratka u zadatku VRP-a.

Jedno od rijetkih istraživanja koje je ispitivalo ulogu distraktora u fazi dosjećanja je ono Beckers i Hömberg (1991). Ovi autori zadavali su fosfene TMS podraživanjem preko okcipitalnog korteksa u fazi zadržavanja i u fazi dosjećanja (nakon prikazivanja testnog ekrana). Istraživanjem nisu pronađene promjene u vremenima reakcije kada je TMS bio zadan u fazi zadržavanja. S druge strane, kada je TMS zadan nakon prikazivanja testnog ekrana, tj. u fazi dosjećanja, vremena reakcije su se u prosjeku produžila. Na temelju ovog istraživanja moguće je pretpostaviti kako i prikazivanje distraktora u fazi dosjećanja može dovesti do interferirajućeg efekta, barem na razini vremena reakcije.

Sprague i sur. (2018) su ispitivali temporalnu dinamiku kodiranja VRP-a koristeći fMR, i to od prikaza podražaja za pamćenje do dosjećanja. Autori su opazili snažnu reprezentaciju u vidnim senzornim područjima tijekom ranih faza obrade nakon čega je slijedilo retinotopna aktivacija u IPS. Na temelju dekodiranja podražaja pomoću opaženih neuralnih signala, pronašli su dokaze o stabilnoj reprezentaciji podražaja u ekstrastrijarnom vidnom i parijetalnom korteksu, područjima ranije sugeriranima kao mjestima primarne pohrane VRP-a. Ključno, stabilne reprezentacije imale su dinamičnu neuralnu podlogu, i to na način da su različita područja nosila informacije o podražajima tijekom obavljanja zadatka. Uzevši u obzir istraživanja opisana u ovom poglavlju, moguće je pretpostaviti kako su reprezentacije u VRP-u najosjetljivije u ranim fazama obrade, konkretno kodiranju i konsolidaciji. Nakon toga, interferirajući efekti vjerojatno ne nestaju, ali na temelju svega prikazanog, izgledno je kako se smanjuju.

2 Cilj istraživanja

U dosadašnjem dijelu rada opisani su nalazi istraživanja uloge distraktora u VRP-u, te nalazi istraživanja manipulacije snage reprezentacija u VRP-u. Cilj ovog rada je povezati i proširiti ove istraživačke teme te provjeriti koliko su reprezentacije podražaja pohranjene u VRP-u otporne na distraktore, a pritom poseban fokus stavljen je i na ulogu snage reprezentacija i na ulogu snage distraktora.

Cilj ovog istraživanja je ispitati ulogu snage distraktora ovisno o snazi reprezentacija podražaja u VRP-u. U tu svrhu provedena su tri eksperimenta. U svakom od njih snaga distraktora operacionalizirana je kao trajanje prikaza distraktora i to na tri razine: bez distraktora, slabi distraktor, snažni distraktor. Eksperimenti su se razlikovala po tome kako smo operacionalizirali snagu reprezentacija podražaja u VRP-u. U svim eksperimentima prepostavili smo kako će snažnije reprezentacije podražaja u VRP-u biti manje osjetljive na distraktore, te da će snažniji distraktori dovesti do većeg interferirajućeg efekta.

U prvom eksperimentu snagu reprezentacija manipulirali smo varirajući broj podražaja koji su sudionici pamtili te vrijeme prikazivanja tih podražaja. Prethodna istraživanja pokazala su kako preciznost dosjećanja varira u funkciji broja podražaja koji se pamti i dostupnog vremena kodiranja i to na način da povećanje broja podražaja koji se pamti te smanjenje vremena dostupnog za kodiranje dovodi do slabije preciznosti dosjećanja (vidi npr. Bays i sur., 2009, 2011).

U drugom eksperimentu snaga reprezentacije manipulirana je prikazivanjem signala unatrag kojim je jednom od prethodno prikazanih podražaja dan prioritet za dosjećanje visoko prediktivnim signalom (eksperiment 2a) odnosno privremeno osvježen neprediktivnim signalom (eksperiment 2b). Prethodna istraživanja demonstrirala su kako je preciznost dosjećanja prioriziranih i osvježenih podražaja bolja u odnosu na podražaje koji nisu priorizirani ili osvježeni (vidi npr. Souza i Oberauer, 2016; Souza i sur., 2015).

U posljednjem eksperimentu snaga reprezentacije manipulirana je variranjem faze obrade unutar koje su prikazani distraktori. Konkretno, distraktori su mogli biti prikazani u ranoj fazi obrade podražaja, tj. tijekom kodiranja, tijekom faze zadržavanja, ili na kraju obrade u fazi dosjećanja. Prethodna istraživanja pružila su nalaze kako su reprezentacije podražaja u VRP-u najosjetljivije, tj. najslabije, u ranim fazama obrade dok kodiranje podražaja u VRP nije dovršeno (vidi npr. Xu, 2017).

Osim ispitivanja interferirajućih efekata uzimajući u obzir jednostavne mjere uratka u zadatku VRP-a, u ovom istraživanju predložili smo i testirali probabilistički model mješovitih

distribucija (Bays i sur., 2009; McLachlan i Peel, 2000) koji pretpostavlja kako svako dosjećanje u zadatku VRP-a dolazi iz jedne od sljedećih kategorija: točno dosjećanje (sudionik se dosjetio traženog podražaja), pogreške zamjene (sudionik se dosjetio prikazanog podražaja, ali ne onog koji je bio tražen), intruzije (sudionik se pogrešno dosjetio distraktora) ili pogađanje (sudionik je odgovarao nasumično). Takav model usporedit će se s jednostavnijim, alternativnim modelom koji pretpostavlja kako su dosjećanja odraz dva moguća stanja: zapamćeno (točna dosjećanja) ili nezapamćeno (slučajna pogađanja).

3 Istraživački problemi i hipoteze

U prvom eksperimentu postavili smo sljedeće istraživačke probleme i pridružene hipoteze:

1. Ispitati ulogu snage distraktora i snage reprezentacija podražaja u VRP-u manipuliranu brojem podražaja koji se pamtio i dostupnim vremenom kodiranja na pogrešku dosjećanja.

Snažniji distraktori dovest će do većeg interferirajućeg efekta, tj. veće pogreške dosjećanja operacionalizirane kao prosječno apsolutno odstupanje. Nadalje, taj efekt bit će izraženiji što će snaga reprezentacije biti slabija. Konkretno, najmanji efekt opaziti ćemo kod pamćenja dva, zatim četiri i naposljetku šest podražaja. Unutar situacije pamćenja različitog broja podražaja, situacije s različitim vremenom kodiranja uslijed prikaza distraktora pratit će trend prema kojem će podražaji kodirani uz duže vrijeme pokazati nižu pogrešku u odnosu na srednje, a zatim i najkraće vrijeme.

2. Ispitati pristajanje podacima modela mješovitih distribucija koji pretpostavlja postojanje točnih dosjećanja, slučajnih pogađanja, pogrešaka zamjene i intruzija, te ispitati ulogu snage distraktora i snage reprezentacija podražaja u VRP-u manipuliranu brojem podražaja koji se pamtio i dostupnim vremenom kodiranja na parametre modela.

Pretpostavljeni model bolje će pristajati podacima od alternativnog jednostavnijeg modela. Nadalje, prikaz distraktora smanjit će vjerojatnost točnih dosjećanja, a pad u toj vjerojatnosti odrazit će se u porastu vjerojatnosti pogrešaka zamjene te pojavi intruzija. Pritom, snažniji distraktori dovest će do snažnijeg efekta. Ponovno, ovi efekti bit će to slabiji što je kvaliteta reprezentacija u VRP-u snažnija.

U drugom eksperimentu postavili smo sljedeće istraživačke probleme i pridružene hipoteze:

1. Ispitati ulogu snage distraktora i snage reprezentacija podražaja u VRP-u manipuliranu davanjem prioriteta reprezentaciji podražaja za dosjećanje (eksperiment 2a) i osvježavanjem reprezentacije podražaja (eksperiment 2b) u VRP-u na pogrešku dosjećanja.

Snažniji distraktori dovest će do većeg interferirajućeg efekta, tj. veće pogreške dosjećanja operacionalizirane kao prosječno apsolutno odstupanje. Taj efekt bit će izražen kod neprioritetnih podražaja, dok kod prioritetnih taj efekt neće biti prisutan (eksperiment 2a). Nadalje, taj efekt bit će prisutan i kod osvježenih i kod neosvježenih podražaja, pri čemu će efekt biti snažniji kod neosvježenih u usporedbi sa osvježenim podražajima (eksperiment 2b).

2. Ispitati pristajanje podacima modela mješovitih distribucija koji pretpostavlja postojanje točnih dosjećanja, slučajnih pogađanja, pogrešaka zamjene i intruzija, te ispitati ulogu snage distraktora i snage reprezentacija podražaja u VRP-u manipuliranu davanjem prioriteta reprezen-

taciji za dosjećanje (eksperiment 2a) i osvježavanjem reprezentacija (eksperiment 2b) u VRP-u. *Pretpostavljeni model bolje će pristajati podacima od alternativnog jednostavnijeg modela. Nadalje, prikaz distraktora smanjit će vjerojatnost točnih dosjećanja, ali samo kod neprioritetnih, no ne i kod prioritetnih podražaja (eksperiment 2a); pad vjerojatnosti točnih dosjećanja uslijed distraktora bit će prisutan i kod osvježenih i neosvježenih podražaja, pri čemu će taj efekt biti veći kod neosvježenih podražaja (eksperiment 2b). Pad u toj vjerojatnosti odrazit će se u porastu vjerojatnosti pogrešaka zamjene te pojavi intruzija. Pritom, snažniji distraktori dovest će do snažnijeg efekta.*

U posljednjem eksperimentu postavili smo sljedeće istraživačke probleme i pridružene hipoteze:

1. Ispitati ulogu snage distraktora i snage reprezentacija podražaja u VRP-u manipuliranu fazom obrade u kojoj je prikazan distraktor.

Snažniji distraktori dovest će do većeg interferirajućeg efekta, tj. veće pogreške dosjećanja operacionalizirane kao prosječno apsolutno odstupanje. Ovaj efekt bit će najizraženiji kada su distraktori prikazani u fazi kodiranja, dok efekt neće postojati kada su distraktori prikazani u fazi zadržavanja i fazi dosjećanja.

2. Ispitati pristajanje podacima modela mješovitih distribucija koji pretpostavlja postojanje točnih dosjećanja, slučajnih pogađanja, pogrešaka zamjene i intruzija, te ispitati ulogu snage distraktora i snage reprezentacija podražaja u VRP-u manipuliranu fazom obrade u kojoj je prikazan distraktor.

Pretpostavljeni model bolje će pristajati podacima od alternativnog jednostavnijeg modela. Nadalje, prikaz distraktora smanjit će vjerojatnost točnih dosjećanja, ali samo kada će distraktori biti prikazani u fazi kodiranja, no ne i u drugim fazama. Pad u toj vjerojatnosti odrazit će se u porastu vjerojatnosti pogrešaka zamjene te pojavi intruzija. Pritom, snažniji distraktori dovest će do snažnijeg efekta.


4 Metoda

4.1 Sudionici

Šezdeset i četiri sudionika (46 ženskih, dob 19 – 31) sudjelovalo je u istraživanju nakon potpisivanja pristanka na sudjelovanje. U prvom eksperimentu sudjelovalo je $N = 30$ (20 ž), drugom (2a i 2b) $N = 22$ (16 ž), i posljednjem $N = 12$ (10 ž) sudionika. Svi sudionici izvijestili su kako imaju zdrav ili odgovarajuće korigiran vid. Kao naknadu za sudjelovanje, ispitanicima su dodijeljeni eksperimentalni sati, kao dio obaveznih zahtjeva na studiju. Istraživanje je odobrilo Etičko povjerenstvo Odsjeka za psihologiju Filozofskog fakulteta u Zagrebu.

4.2 Zadatak kontinuirane procjene

U svakom od provedenih eksperimenata kao zadatak za ispitivanje VRP-a korišten je zadatak kontinuirane procjene uz odgođeno dosjećanje. Pojednostavljeni prikaz ovog zadatka vidljiv je na slici 1. U takvom zadatku sudionicima se na početku svake sekvence prikazuju podražaji za pamćenje, a mi smo kao podražajni materijal koristili boje. Nakon kratkog prikaza za pamćenje slijedi faza zadržavanja u kojoj se sudionicima najčešće prikazuje samo fiksacijski križić. Ovaj prikaz slijedi signaliziranje jednog od prethodno prikazanih podražaja, a svrha ovog signaliziranja je određivanje podražaja čije će se kvalitete (u našem slučaju boje) sudionici morati dosjetiti. Kao signal se koristi isticanje lokacije jednog od prikazanih podražaja. Sudionici zatim na krugu boja pokazivačem miša odabiru što precizniju nijansu boje koja, prema onom što su zapamtili, odgovara podražaju prikazanom na prethodno signaliziranoj lokaciji.



Slika 1. Shematski prikaz zadatka kontinuirane procjene.

4.3 Podražajni materijal

Svi podražaji bili su prikazani na 24" LCD monitoru (Asus vg248qe) rezolucije 1920x1080 sa 144Hz vertikalnog osvježavanja. Sudionici su od ekrana bili udaljeni 70cm, a konstantan razmak osiguran je korištenjem naslona za glavu. Podražaji su prezentirani na sivoj pozadini ekrana (5 cd/m^2) u zatamnjenoj sobi (0.1 lux).

Podražajni materijal u zadatku radnog pamćenja u svim provedenim eksperimentima bile su boje. Sudionicima su u istraživanju prikazivani obojeni kvadrati (2, 3, 4 ili 6 njih, ovisno o eksperimentu), a njihov zadatak bio je da zapamte prezentirane boje. Svaki obojeni kvadrat zauzimao je površinu $2^\circ \times 2^\circ$ vidnog polja i bio je centriran na nevidljivoj kružnici radijusa 5.2° vidnog polja sa središtem u centru ekrana. Lokacije podražaja bile su odabrane po slučaju između osam unaprijed određenih i na kružnici međusobno jednako udaljenih lokacija. Boje kvadrata odabirane su po slučaju između 180 mogućih boja, uniformno raspoređenih na krugu radijusa 89 u CIE $L^*a^*b^*$ prostoru boja ($L = 70$, $a = 20$, $b = 38$).

Podražajni materijal u interferirajućem prikazu po svim karakteristikama bio je jednak podražajnom materijalu u prikazu za pamćenje: veličine podražaja, način odabira boja i njihov razmještaj bili su jednaki kao i u zadatku pamćenja. Kako bismo se osigurali da će sudionici usmjeriti pažnju na interferirajući prikaz i ne ignorirati ga, osmislili smo jednostavan zadatak detekcije podražaja. U svakom eksperimentu, u 40% slučajno odabranih sekvenci smo uz obojene kvadrate sudionicima prezentirali crno-bijeli podražaj nalik šahovskoj ploči ($2^\circ \times 2^\circ$ vidnog polja, 24×24 polja naizmjenično obojenih crnom i bijelom bojom). Veličina tog podražaja bila jednaka veličini obojenih kvadrata, a lokacija prikaza bila je odabrana po slučaju između osam mogućih lokacija, istih onih korištenih kod prikaza podražaja za pamćenje. Zadatak sudionika bio je da detektiraju je li zajedno s distraktorima (obojenim kvadratima) bio prikazan takav podražaj. U 40% slučajno odabranih sekvenci, sudionici su na kraju sekvence, nakon dosjećanja boja odgovarali jesu li primijetili podražaj i to klikom miša na jednu od dvije opcije ('DA' ili 'NE').

Za kontrolu vremena pamćenja podražaja za pamćenje u eksperimentu 1 te za kontrolu vremena prikaza distraktora u svim eksperimentima korišten je maskirajući podražaj. On se sastojao od prikaza statičnog obojenog šuma unutar kružnice (radijus 10.6° vidnog polja). Trajanje prikaza maskirajućeg podražaja uvijek je iznosilo 80ms. Paradigma maskiranja klasičan je pristup kontrole vremena kodiranja vidnih informacija (Breitmeyer i Ogmen, 2000). Uloga maskirajućeg podražaja jest da u vidnom sustavu zamijeni prethodno percipirane vidne podražaje i na taj način zaustavi njihovo kodiranje. Naknadno ispitivanje dosjećanja podražaja nakon kojih je prikazana maska pokazuje koliko dobro su kodirani vidni podražaji u ograničenom vremenu (Bays i sur., 2011; Gegenfurtner i Sperling, 1993; Vogel i sur., 2006).

U svim eksperimentima sudionici su odgovore u zadatku dosjećanja radnog pamćenja davali klikom miša na krug boja. Na krugu boja bilo je prikazano 180 boja i odražavao je isti prostor boja iz kojeg su uzorkovani podražaji za pamćenje i interferenciju. Krug je imao središte u centru ekrana, unutarnji radijus iznosio je 7.6° , a vanjski 10.6° stupnjeva vidnog polja.

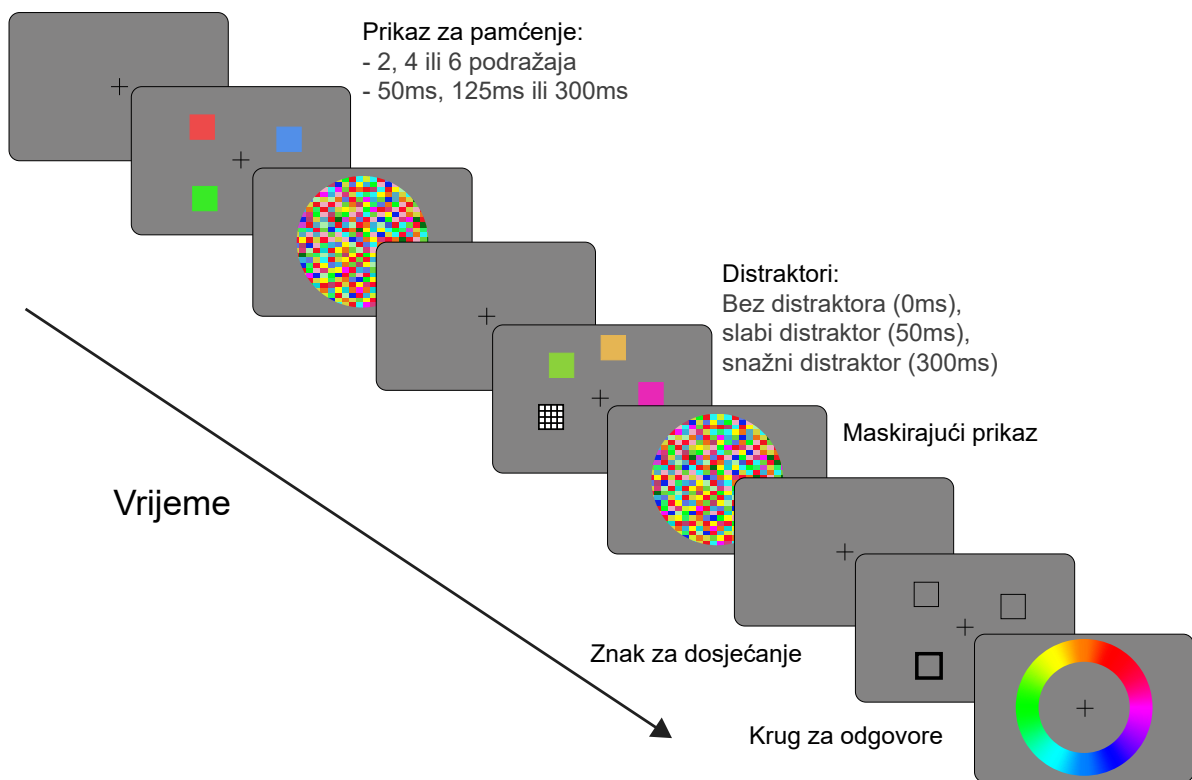
Snagu distraktora kontrolirali smo manipuliranjem vremena trajanja njihovog prikaza, i to na tri razine. U kontrolnoj situaciji sudionicima nisu prikazani distraktori ('Bez distraktora'). Druga razina nezavisne varijable snage distraktora, 'Slabi distraktori', u svim eksperimentima označava prikaz distraktora u trajanju od 50ms. Konačno, treća razina nezavisne varijable snage distraktora, 'Snažni distraktori', definirano je u skladu s trajanjem podražaja za pamćenje, i uvijek je iznosilo koliko i (najduže) trajanje prikaza za pamćenje: u eksperimentu 1 300ms, u eksperimentima 2a i 2b 150ms, u eksperimentu 3 200ms.

4.4 Postupak

4.4.1 Eksperiment 1

U prvom eksperimentu željeli smo provjeriti kakva je uloga snage distraktora ovisno o početnoj snazi reprezentacije VRP-a, manipulirane brojem elemenata koji se pamti i dostupnim vremenom kodiranja. Eksperimentalni nacrt bio je mješovit 3 (broj elemenata: 2, 4, 6) x 3 (vrijeme kodiranja: 50ms, 125ms, 300ms) x 3 (snaga distraktora: bez distraktora (0ms), slabi distraktor (50ms), snažni distraktor (300ms)). Sudionici su bili u nezavisni s obzirom na faktor broj podražaja koji se pamti i zavisni po preostala dva faktora. Shematski prikaz zadatka korištenog u eksperimentu 1 prikazan je na slici 2.

Na početku svake sekvence (slika 2) sudionicima je bio prikazan fiksacijski križić ($0.9^\circ \times 0.9^\circ$). Nakon 750ms prikazana su im 2, 4 ili 6 obojena kvadrata ($2^\circ \times 2^\circ$) na po slučaju odabranim lokacijama od osam unaprijed određenih lokacija raspoređenih na nevidljivom krugu s centrom u središtu ekrana (radijus kružnice 5.2°). Prezentacija podražaja koje su sudionici pamtili trajala je 50ms, 125ms ili 300ms, a nakon nje je uslijedio maskirajući podražaj (80ms), a zatim prikaz fiksacijskog križića (1100ms). Nakon toga uslijedio je prikaz distraktora koji se uvijek sastojao od četiri po slučaju odabrane boje. Distraktori su prikazani na po slučaju odabranim lokacijama između osam unaprijed definiranih lokacija raspoređenih na nevidljivom krugu s centrom u središtu ekrana (radijus 5.2°). Prikaz distraktora bio je izostavljen u kontrolnoj situaciji (bez distraktora), te je trajao 50ms (slabi distraktor) ili 300ms (snažni distraktor) u preostale dvije situacije; nakon njega je uvijek prikazan maskirajući podražaj (80ms). Nakon nestanka maskirajućeg podražaja, na ekranu je bio prikazan samo fiksacijski križić, a njegovo trajanje bilo je varijabilno i na svakoj sekvenci je određeno kao 3750ms umanjeno za



Slika 2. Shematski prikaz eksperimentalnog zadatka korištenog u eksperimentu 1. Veličina, razmještaj i boje podražaja ne odgovaraju prikazima u eksperimentu. U prikazanoj sekvenci, uz distraktore je prikazan i rešetkasti podražaj kojeg su sudionici trebali detektirati. Pitanje o tom podražaju je izostavljeno iz shematskog prikaza.

trajanja svih ostalih prikaza u sekvenci. Cjelokupno trajanje sekvence do trenutka davanja odgovora iznosilo je 3750ms i držano je konstantno, neovisno o trajanju vremena kodiranja ili trajanju distraktora. Fiksacijski križić je stoga mogao biti prikazan između 640ms (300ms vrijeme kodiranja i 300ms vrijeme interferencije) i 1190ms (50ms vrijeme kodiranja i 0ms vrijeme interferencije). Na taj način je u svakoj sekvenci ukupno vrijeme od prikazivanja podražaja za pamćenje do trenutka davanja odgovora bilo jednako. Naposljetku, znak za dosjećanje u obliku kvadrata zatamnjenih rubova na jednoj od lokacija na kojoj su bile prikazane boje za pamćenje, prikazan je na 500ms. Uslijedio je prikaz kruga boja na kojem su sudionici klikom miša odabirali boju kvadratića koju su zapamtili. Vrijeme davanje odgovora nije bilo ograničeno. U 40% sekvenci, nakon davanja odgovora, sudionike smo tražili da odgovore jesu li u prikazu s distraktorima primijetili rešetkasti podražaj. Sudionici su davali odgovore klikom miša unutar odgovarajućeg prostora na ekranu (tipke s opcijama 'DA' i 'NE'). Nakon toga, uslijedila je nova sekvenca.

Za svakog sudionika zadatak je bio podijeljen u 9 blokova od kojih se svaki sastojao od 81 sekvence. Sudionici su zadatak rješavali u dva termina s maksimalnim razmakom između dva mjerenja u trajanju od dva tjedna. U svakom bloku sudionici su imali jednak broj podražaja

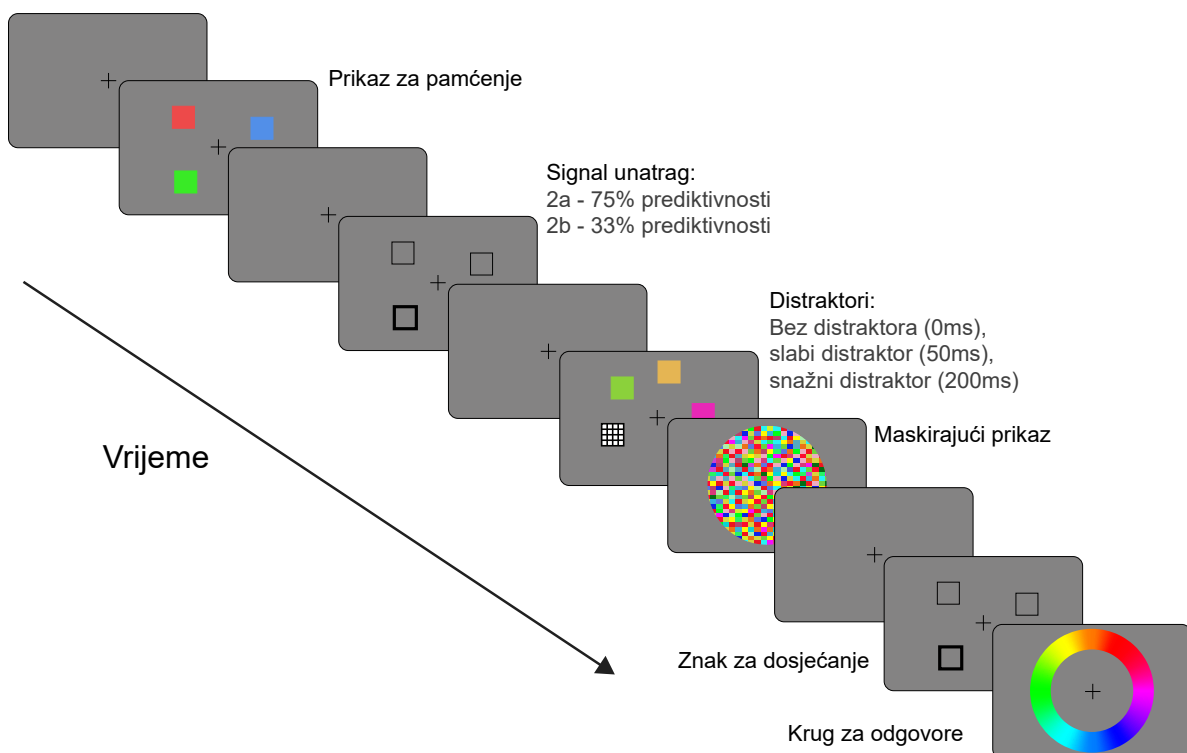
iz svake od devet eksperimentalnih situacija, a njihov redoslijed određen je po slučaju. Na početku oba termina, sudionici su prošli kroz kratku vježbu (45 sekvenca ukupno) koja je po svim karakteristikama odgovarala glavnom dijelu istraživanja. Jedan je sudionik izbačen iz obrade zato što je sudjelovao samo u prvom dijelu mjerenja. Ukupan broj sudionika u ovom eksperimentu iznosio je 29.

4.4.2 Eksperiment 2

U drugom eksperimentu željeli smo ispitati ulogu snage distraktora s obzirom na snagu reprezentacije u VRP, manipuliranu davanjem prioriteta podražaju za dosjećanje (Eksperiment 2a) i osvježavanjem reprezentacija (Eksperiment 2b).

Eksperiment 2a

U eksperimentu 2a nacrt je bio potpuno zavisian i složen s faktorima prioritet podražaja za dosjećanje (prioritetan, neprioritetan) i snaga distraktora (bez distraktora (0ms), slabi distraktor (50ms), snažni distraktor (200ms)). U eksperimentu je sudjelovalo $N = 12$ sudionika. Veličine i razmještaj svih podražaja bile su jednake onima u eksperimentu 1. Shematski prikaz zadatak prikazan je na slici 3.



Slika 3. Shematski prikaz eksperimentalnog zadatka korištenog u eksperimentima 2a i 2b. Veličina, razmještaj i boje podražaja ne odgovaraju prikazima u eksperimentu. U prikazanoj sekvenci, uz distraktore je prikazan i rešetkasti podražaj kojeg su sudionici trebali detektirati. Pitanje o tom podražaju je izostavljeno iz shematskog prikaza.

Svaka sekvenca započela je prikazivanjem fiksacijskog križića (750ms) na sredini ekrana. Nakon toga uslijedio je prikaz podražaja za pamćenje koji se sačinjavao od tri obojena kvadrata (200ms), a zatim prikaz praznog ekrana s fiksacijskim križićem (1000ms). Prikaz sa signalom unazad izgledao je isto kao i znak za dosjećanje - na lokacijama prethodno prikazanih boja nalazili su se neispunjeni kvadrati, a jedan od njih je imao zadebljane stranice. Sudionicima je rečeno kako je signal prediktivan za to koji će element biti tražen za dosjećanje. U eksperimentu 2a od sudionika je na 75% sekvenci traženo da se dosjete signaliziranog podražaja, odnosno podražaja kojeg je signal prioritizirao za dosjećanje. U preostalih 25% sekvenci od sudionika je traženo da se dosjete jednog od 2 preostala, nesignalizirana podražaja, odnosno podražaja koji prethodno signalom nisu označeni kao prioritetni za dosjećanje. Tijekom upute, sudionicima je rečeno kako pouzdanost signala unatrag nije 100%, no nije im rečeno kolika je točna njegova pouzdanost. Signal unazad prikazivan je 300ms. Prikaz distraktora sastojao se od tri po slučaju odabrane boje i bio je prezentiran 200ms nakon nestanka signala unazad. Prikaz distraktora bio je izostavljen u kontrolnoj situaciji (bez distraktora), te je trajao 50ms (slabi distraktor) ili 200ms (snažni distraktor) u preostale dvije situacije; nakon njega je uvijek prikazan maskirajući podražaj (80ms). Najduža prezentacija distraktora usklađena je s vremenom prezentacije podražaja za pamćenje u eksperimentu 2. Uslijedio je još jedan fiksacijski križić čije je trajanje bilo određeno tako da cjelokupna sekvenca, neovisno o trajanju distraktora, iznosi 3500ms. Trajanje tog fiksacijskog križića stoga je moglo iznositi 470ms (bez distraktora), 420ms (50ms distraktora) ili 270ms (200ms distraktora). Znak za dosjećanje prikazan je na 500ms nakon čega su sudionici klikom miša odgovarali koju su boju zapamtili na lokaciji znaka za dosjećanje. Nakon odgovaranja, u 40% po slučaju odabranih sekvenci, sudionici su odgovarali na pitanje jesu li primijetili rešetkasti podražaj u prikazu s distraktorima.

Ukupan broj sekvenci kroz koje su sudionici prošli varirao je ovisno o eksperimentalnoj situaciji. Kako bismo imali dovoljan broj podražaja za sve planirane analize u svim eksperimentalnim situacijama, sudionici su odradili 639 sekvenci, od čega su se 480 puta dosjećali podražaja signaliziranog kao prioritetnog za dosjećanje, a 159 puta dosjećali jednog od preostalih, neprioritetnih podražaja. Unutar ovih brojeva dosjećanja, na jednakom broju sekvenci (160 odnosno 53) nije bio prikazan distraktirajući podražaj, bio je prikazan slab ili snažan distraktor.

Cijeli eksperimentalni zadatak bio je podijeljen u osam blokova pri čemu su duljine blokova bile varijabilne (2 bloka s 90 sekvenci, 3 bloka s 81 sekvencom, 3 bloka sa 72 sekvence). Na taj način željeli smo smanjiti ulogu umora te su sudionici prvo odradili duže, a na kraju kraće blokove. Prije početka mjerenja svaki sudionik odradio je 27 sekvenci za vježbu. Unutar svakog bloka prezentiran je jednak broj podražaja iz svake eksperimentalne situacije, a redosljed im je određen po slučaju. Sudionici su zadatak rješavali u jednom terminu.


Eksperiment 2b

U eksperimentu 2b nacrt je bio potpuno zavisan i složen s faktorima osvježavanja reprezentacija (osvježene, neosvježene) i snaga distraktora (bez distraktora (0ms), slabi distraktor (50ms), snažni distraktor (200ms)). U eksperimentu je sudjelovalo N = 10 sudionika. Eksperiment 2b po svim karakteristikama bio je identičan eksperimentu 2a, uz sljedeće izuzetke. Signal prikazan u fazi zadržavanja nije bio prediktivan za to kojeg će se podražaja sudionici morati dosjetiti. Drugim riječima, kako su sudionici pamtili 3 podražaja, signal je bio pouzdan na razini slučaja, odnosno u 33% sekvenci. Na taj način, sudionici su se u 33% slučajeva dosjećali podražaja koji je bio osvježen mehanizmom *odozdo-prema-gore*, dok su se u preostalih 67% sekvenci dosjećali jednog od preostala dva podražaja koji nisu bili osvježeni. Ukupan broj sekvenci u eksperimentu 2b iznosio je 576 i sudionici su ovaj zadatak odrađivali u 8 blokova jednake duljine. Uzevši u obzir eksperimentalne manipulacije, sudionici su se ukupno 189 puta dosjećali osvježenog podražaja (63 puta uz svaku razinu nezavisne varijable snage distraktora), i 387 puta kada podražaj nije bio osvježen.

4.4.3 Eksperiment 3

U trećem eksperimentu željeli smo ispitati ulogu snage distraktora s obzirom na snagu reprezentacije u VRP-u, određenu fazom obrade u VRP-u u kojoj se prikazuje distraktirajući materijal. Eksperimentalni nacrt bio je potpuno zavisan i složen s faktorima faze obrade (kodiranje, zadržavanje, dosjećanje) i snaga distraktora (bez distraktora (0ms), slabi distraktor (50ms), snažni distraktor (150ms)). U eksperimentu je sudjelovalo N = 12 sudionika. Shematski prikaz korištenog zadatka vidljiv je na slici 4.

Na početku svake sekvence sudionicima je bio prikazan fiksacijski križić na sredini ekrana (750ms), nakon čega su im prikazana tri obojena kvadrata (150ms) čije su boje sudionici morali pamtili. Odabirom tri podražaja za pamćenje željeli smo stvoriti zadatak optimalne težine, a odabirom vremena kodiranja od 150ms stvoriti uvjet za interferiranje u fazu kodiranja, prije nego li sudionici stvore stabilnu reprezentaciju (vidi Bays i sur., 2011). Nakon prikaza za pamćenje uslijedio je fiksacijski križić, a njegovo trajanje ovisilo je o eksperimentalnoj situaciji. Kada su distraktori prikazani u fazi kodiranja, fiksacijski križić trajao je 20ms, nakon čega je uslijedila prezentacija distraktora. Kada je interferirajući prikaz prezentiran u fazi zadržavanja, fiksacijski križić bio je prezentiran 2500ms, nakon čega je uslijedila prezentacija distraktora. Interferirajući prikaz sastojao se od tri obojana kvadrata i bio je izostavljen u kontrolnoj situaciji (bez distraktora), te prikazan na 50ms (slabi distraktor) ili 150ms (snažni distraktor) u preostale dvije situacije. Najduža prezentacija distraktora usklađena je s vremenom prezentacije podražaja za pamćenje u eksperimentu 3. Nakon prikaza distraktora uslijedila je prezentacija maskirajućeg prikaza (80ms). Naposljetku, prezentiran je još jedan fiksacijski križić (trajanje



Slika 4. Shematski prikaz eksperimentalnog zadatka korištenog u eksperimentu 3. Zbog preglednosti iz prikaza su izostavljeni ekrani na kojima su prikazani samo fiksacijski križići. U prvom retku prikazana je sekvenca s prikazom distraktora u fazi kodiranja, u drugom retku sekvenca s prikazom distraktora u fazi zadržavanja, te u trećem retku sekvenca s prikazom distraktora u fazi dosjećanja. U sva tri slučaja sekvenca je ukupno trajala 4750ms. Veličina, razmještaj i boje podražaja ne odgovaraju prikazima u eksperimentu. U prikazanim sekvencama, uz distraktore je prikazan i rešetkasti podražaj kojeg su sudionici trebali detektirati. Pitanje o tom podražaju je izostavljeno iz shematskog prikaza.

varijabilno: 4750ms - trajanje ostatka prikaza) te znak za dosjećanje (500ms). Sudionici su nakon toga klikom miša na krug boja davali odgovor koja je boja bila prikazana na lokaciji znaka za dosjećanje. U 40% po slučaju odabranih sekvenci, nakon dosjećanja boja, sudionici su odgovarali na pitanje jesu li primijetili rešetkasti podražaj u prikazu s distraktorima.

U situaciji prikaza distraktora u fazi dosjećanja sekvenca je izgledala kao i u preostale dvije situacije sa sljedećim iznimkama: fiksacijski križić nakon prikaza za pamćenje trajao je varijabilno ovisno o trajanju distraktora i na način da svi prikazi od početka sekvence do početka davanja odgovora traju 4750ms; nakon tog fiksacijskog križića uslijedio je znak za dosjećanje, a tek zatim distraktirajući prikaz a potom i maskirajući prikaz.

Sudionici su ukupno prošli kroz 459 sekvenci, od kojih je njih 27 bilo za uvježbavanje. Svaki sudionik odradio je 48 sekvenci po eksperimentalnoj situaciji, a cjelokupni zadatak bio je podijeljen u šest blokva. Unutar svakog bloka prezentiran je jednak broj podražaja iz svake eksperimentalne situacije, a redoslijed im je određen po slučaju. Sudionici su zadatak rješavali u jednom terminu.

4.5 Strategija analize podataka

U svakom od opisanih eksperimenata zabilježeni su odgovori sudionika na krugu boja te je za svako dosjećanje izračunata pogreška dosjećanja kao razlika tražene boje i boje koje su se sudionici dosjetili. Uslijed relativno većeg broja sekvenci po eksperimentalnoj situaciji u svakom od eksperimenata raspolagali smo distribucijom dosjećanja za svakog sudionika u svakoj eksperimentalnoj situaciji. Ove distribucije tipično imaju oblik normalne distribucije i služile su nam kao osnova za sve daljnje obrade. Primarna zavisna varijabla bila je prosječno apsolutno odstupanje pogrešaka oko vrijednosti traženih za dosjećanje, izražena u radijanima. Ova mjera raspršenja odabrana je prvenstveno zbog toga što ne pretpostavlja, tj. ne zahtjeva određen oblik distribucije. Iako distribucija pogrešaka dosjećanja u zadacima VRP-a nalikuje normalnoj distribuciji, istraživanja konzistentno pokazuju izraženu kurtičnost. Nadalje, modeli mješovitih distribucija koji se često koriste u obradi podataka uratka u ovakvim zadacima, pretpostavljaju kako se distribucija pogrešaka ne može zahvatiti jedinstvenom distribucijom, već da je kombinacija nekoliko različitih distribucija, npr. nekoliko normalnih i uniforme distribucije. Naposljetku, prosječno apsolutno odstupanje ima relativno intuitivnu interpretaciju - vrijednost 0 znači da ne postoji nikakvo raspršenje, dok vrijednost 1.5708 (u radijanima) pokazuje kako je raspršenje potpuno (uniformna distribucija).

Analiza svakog eksperimenta započinje usporedbom prosječnih apsolutnih odstupanja u eksperimentalnim situacijama kada nije prikazan distraktor. Nakon toga prikazani su rezultati točnosti detekcije ciljnog podražaja prikazanog uz distraktore, i to s ciljem provjere jesu li sudionici obraćali pažnju na distraktore. Nakon toga slijedi analiza prosječnih apsolutnih odstupanja za sve manipulirane faktore u istraživanju. Uradak preko različitih eksperimentalnih situacija uspoređen je prvenstveno složenim analizama varijance. Kao naknadni testovi korištene su jednosmjerne analize varijance i t testovi koristeći Bonferronijevu korekciju. Osim tradicionalnih p vrijednosti, u ovom radu svaki testirani efekt provjeren je istom analizom u okviru Bayesove statistike. Tradicionalni, frekvencionistički pristup statistici zasniva donošenje odluka o alternativnoj hipotezi (prihvatanje ili odbacivanje) na temelju odbacivanja nul hipoteze provjeravajući koja je vjerojatnost opažanja istog ili ekstremnijeg rezultata u ponovljenom mjerenju, uz pretpostavku o točnosti nul hipoteze. Drugim riječima, ovaj pristup postavlja pitanje kolika je izglednost (eng. *likelihood*) opažanja nekog skupa podataka uz pretpostavku da je (nul) hipoteza točna. Jedna od najčešćih pogrešnih interpretacija p vrijednosti jest kako ona pokazuje kolika je vjerojatnost da je alternativna hipoteza točna, međutim, ta interpretacija logički nikako ne može proizaći iz prirode izračuna p vrijednosti. Nepotvrđivanje jedne hipoteze (nul) ne može biti potvrda druge hipoteze (alternativne).

Bayesov pristup testiranju hipoteza s druge strane postavlja pitanje kolika je vjerojatnost

opažanja nekog seta podataka pod pretpostavkom da je određena hipoteza točna (za detaljan pregled Bayesijanskog donošenja odluka i pristupa statističkom rezoniranju vidi Etz i Vandekerckhove, 2018; Kruschke i Liddell, 2018; Wagenmakers, Lee, Lodewyckx i Iverson, 2008). U okviru Bayesovog zaključivanja, ključno pitanje je kolika je vjerojatnost hipoteze uzevši u obzir opažene rezultate, tj. kakva je posteriorna vjerojatnost neke hipoteze. Posteriorna vjerojatnost ovisi o izglednosti rezultata u vidu neke hipoteze te apriorne vjerojatnosti te hipoteze. Kako bi odgovorio na to pitanje, Bayesov pristup usmjerava se upravo na usporedbu vjerojatnosti rezultata pod najmanje dvije hipoteze - nul i alternativne. Na taj način, o vjerojatnosti alternativne hipoteze ne moramo zaključivati na temelju testa nul hipoteze, već na temelju testa alternativne hipoteze i usporedbom vjerojatnosti dobivanja podataka pod nul i alternativnom hipotezom. U kontekstu usporedbe dviju hipoteza Bayesovo pravilo možemo prikazati kao:

$$\frac{p(H_1|podaci)}{p(H_0|podaci)} = \frac{p(H_1)}{p(H_0)} \times \frac{p(podaci|H_1)}{p(podaci|H_0)} \quad (1)$$

pri čemu lijevi član nazivamo posteriornim izgledima, srednji član apriornim izgledima, a desni član Bayesovim faktorom, dobiven kao omjer izglednosti podataka pod dvije hipoteze. Iz formule proizlazi kako, da bismo opazili posteriornu plauzibilnost hipoteza, apriornu plauzibilnost hipoteze moramo korigirati za vrijednost koja odgovara Bayesovom faktoru. Uz pretpostavljenu jednaku vjerojatnost istinitosti dvije hipoteze, Bayesov faktor i posteriorna vjerojatnost hipoteze su proporcionalni. U ovom radu p vrijednost kod svakog testa, prati i Bayesov faktor, i to u konkretnoj formi BF_{10} koja pokazuje koliko su puta opaženi podaci vjerojatniji pod alternativnom hipotezom (H_1), nego nul hipotezom (H_0). Na primjer, $BF_{10} = 5$ govori kako su opaženi podaci pet puta vjerojatniji pod alternativnom nego nul hipotezom. Vrijednost recipročna BF_{10} (npr. $1/5$), označava se kao BF_{01} i pokazuje koliko su puta podaci vjerojatniji pod nul u odnosu na alternativnu hipotezu.

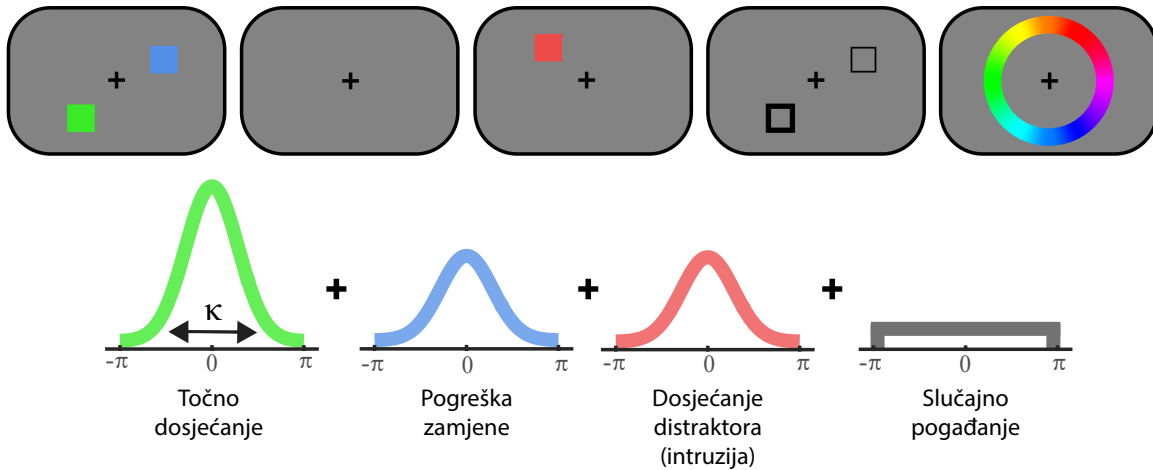
Kod testiranja hipoteze Bayesovim t-testom za reprezentaciju alternativne hipoteze korišten je Cauchyjev prior ($0, r = 0.707$) postavljen na veličinu efekta (za nul hipotezu prior iznosi $\delta = 0$), a Bayesov faktor izračunat je pomoću Savage-Dickey omjera gustoća (Dickey, 1971). Kod jednosmjerne i višesmjerne analize varijance za ponovljena mjerenja postavljen je Cauchyjev prior ($0, r = 0.5$) na veličinu efekta, a Bayesov faktor izračunat je uz pomoć Monte Carlo simulacije (za detalje vidi Rouder, Morey, Speckman i Province (2012)). Odabir ovih konkretnih prior distribucija objašnjen je detaljnije u Rouder i Morey (2012) i Rouder i sur. (2012), no napomenimo da ove distribucije odgovaraju tipičnim veličinama efekata pronađenima u psihološkim istraživanjima. Prilikom provedbe Bayesove višesmjerne analize varijance, naglasak je stavljen na traženje skupa faktora i njihovih interakcija koji najbolje objašnjavaju podatke (slično regresijskoj analizi i zadržavanju prediktora na temelju objašnjavanja podataka). Ishod

Bayesove analize varijance su stoga Bayesovi faktori većeg broja modela koji sadrže kombinacije faktora i njihovih interakcija, pri čemu interakcije ulaze u modele samo ako su u njima prisutni faktori koji čine tu interakciju. Cilj je odabrati model koji sadrži one glavne efekte i interakcije koji najviše mijenjaju apriorna očekivanja. Stoga je kod provedbe višesmjernje analize varijance naveden BF_{inc} (BF uključivanja), koji pokazuje koliko uključivanje nekog faktora u model, uprosječno preko svih modela u kojima se taj faktor mogao naći, mijenja apriorna očekivanja o plauzibilnosti hipoteze. Ako je BF_{inc} za neki faktor visok, prikupljeni podaci favoriziraju modele koji sadrže taj konkretan faktor. Recipročna vrijednost BF_{inc} je BF_{excl} (BF isključivanja) i pokazuje u kojoj mjeri podaci favoriziraju modele koji isključuju konkretan faktor. Vrijednosti Bayesovih faktora (BF_{10}) tumače se kao snaga dokaza za alternativnu u usporedbi s nul hipotezom, i to na sljedeći način: 1 - nema dokaza, 1-3 - anegdotalni dokazi, 3-10 - umjereni dokazi, 10-30 - snažni dokazi, 30-100 - vrlo snažni dokazi, >100 iznimno snažni dokazi (u prilog alternativnoj hipotezi). Za interpretaciju snage dokaza u korist nul hipoteze, računa se vrijednost recipročna BF_{10} i koriste se isti ovi kriteriji.

Nakon analize prosječnih apsolutnih odstupanja, podaci su testirani probablističkim modelom mješovitih distribucija (McLachlan i Peel, 2000). Dok analiza prosječnih apsolutnih odstupanja pokazuje kako se preciznost dosjećanja mijenja s eksperimentalnim manipulacijama, parametri modela mješovitih distribucija pokazuju zašto se preciznost dosjećanja mijenja. Konkretno, porast prosječnih apsolutnih odstupanja u nekoj situaciji može biti posljedica slučajnog pogađanja, nenamjernog dosjećanja distraktora ili pak točnog dosjećanja ali uz vrlo nisku preciznost. U ovom radu pretpostavili smo kako dosjećanje u zadatku VRP-a možemo opisati točnim dosjećanjima, slučajnim pogađanjima, pogreškama zamjene, te u situacijama kada je prikazan distraktor, intruzijama distraktora. Formalno, dosjećanje prema ovom modelu možemo opisati:

$$p(\hat{\theta}) = p_t \phi_{\kappa}(\hat{\theta} - \theta) + p_{pz} \frac{1}{m} \sum_i^m \phi_{\kappa}(\hat{\theta} - \theta_i^*) + p_{int} \frac{1}{n} \sum_j^n \phi_{\kappa}(\hat{\theta} - \theta_j^*) + \frac{(1 - p_t - p_{pz} - p_{int})}{2\pi}. \quad (2)$$

gdje je p_t vjerojatnost točnog dosjećanja, ϕ_{κ} je cirkularna normalna (Von Mises) distribucija s koncentracijskim parametrom κ , $\hat{\theta}$ je vrijednost dosjećanja (na krugu boja), θ je tražena boja, p_{pz} je vjerojatnost pogreške zamjene, odnosno dosjećanja boje prikazane za pamćenje, ali one koja nije tražena za dosjećanje, $\{\theta_1^*, \theta_2^*, \dots, \theta_m^*\}$ su vrijednosti boja prikazanih za pamćenje, ali onih koje nisu tražene za dosjećanje, p_{int} je vjerojatnost intruzije, odnosno dosjećanja distraktora, $\{\theta_1^*, \theta_2^*, \dots, \theta_n^*\}$ su vrijednosti boja distraktora; posljednja komponenta ove formule odnosi se na vjerojatnost pogađanja. Ilustracija ovog modela prikazana je na slici 5.



Slika 5. Ilustracija modela mješovitih distribucija. Pogreška dosjećanja na svakoj sekvenci dolazi iz jedne od četiri komponente: na svakoj sekvenci može biti posljedica točnog dosjećanja (uz preciznost κ), pogreške zamjene, intruzija ili slučajnog pogađanja.

Na sekvencama na kojima nije prikazan distraktor (kontrolna situacija s obzirom na faktor snage distraktora), intruzije nisu bile moguće te je provjereno pristajanje gornjeg modela, ali bez komponente intruzija. Matematički ovaj model možemo opisati:

$$p(\hat{\theta}) = p_t \phi_{\kappa}(\hat{\theta} - \theta) + p_{pz} \frac{1}{m} \sum_i^m \phi_{\kappa}(\hat{\theta} - \theta_i^*) + \frac{(1 - p_t - p_{pz})}{2\pi}. \quad (3)$$

gdje su sve komponente iste kao u (2). Pristajanje ovih modela uspoređeno je s jednostavnijim modelom koji pretpostavlja dva stanja vidne reprezentacije: zapamćeno ili nezapamćeno odnosno zaboravljeno. Takav uradak možemo opisati komponentom normalne distribucije koja opisuje točna dosjećanja, te komponentom uniformne distribucije koja opisuje slučajna pogađanja:

$$p(\hat{\theta}) = p_t \phi_{\kappa}(\hat{\theta} - \theta) + \frac{(1 - p_t)}{2\pi}. \quad (4)$$

Parametri najbolje pristajućeg modela dobiveni *maximum likelihood* metodom minimizacije koristeći *Interior-point* algoritmom (*fmincon* u Matlabu). Modeli su uspoređeni koristeći Akaikijev informacijski kriterij (AIC) izračunat kao $AIC = 2k - 2\ln(L)$, pri čemu k označava broj parametara, a $\ln(L)$ logaritam izglednosti dobivenih parametara uz dane podatke. Kako bismo provjerili koliko dobro pretpostavljeni model reproducira pogreške dosjećanja, na temelju dobivenih parametara simulirana su očekivana prosječna apsolutna odstupanja. Za svaku eksperimentalnu situaciju (u svakom od provedenih eksperimenata) vrijednosti su simulirane metodom inverznog uzorkovanja iz kumulativne distribucije dobivene pomoću parametara mo-

dela. Svaka simulirana vrijednost dobivena je uprosječivanjem 100 uzorkovanja pri čemu je u svakom uzorkovanju po slučaju odabrano 80 vrijednosti (na temelju prosječnog broja sekvenci koje su sudionici imali po eksperimentalnoj situaciji). Za simuliranje vrijednosti u situacijama u kojima je prikazan distraktor poslužili su parametri punog modela (opisan u jednadžbi (2)) dok su u kontrolnoj situaciji korišteni parametri istog modela, no bez intruzija (opisan u jednadžbi (3)). Sve analize prikazane u ovom radu provedenu su u programima Matlab (The Mathworks Inc.) i JASP (JASP Team 2018, verzija 0.9.1).

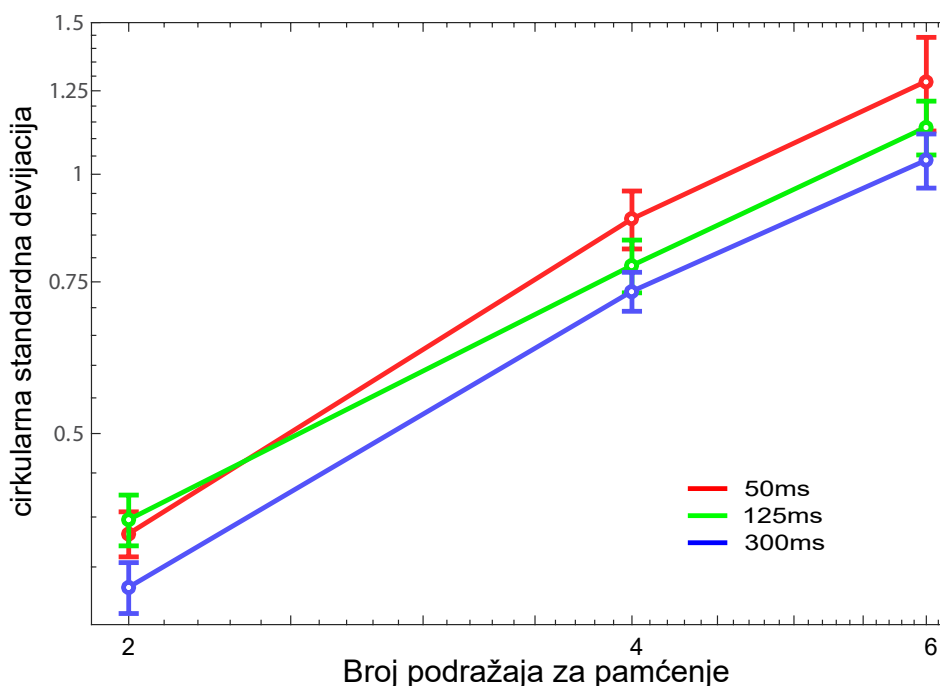
5 Rezultati i rasprava

5.1 Eksperiment 1

U prvom eksperimentu cilj je bio provjeriti ulogu snage distraktora u stvaranju interferirajućeg efekta kod reprezentacija VRP-a različite početne snage, manipulirane brojem podražaja koji se pamtio i dostupnim vremenom kodiranja. Tri grupe sudionika pamtile su različit broj podražaja: 2, 4 ili 6. Svaka od tri dužine niza mogla je biti prikazana jednim od tri vremena kodiranja: 50ms, 125ms, 300ms. Na taj način cilj je bio stvoriti različite situacije početne kvalitete reprezentacija. Konačno, sudionicima su tijekom zadržavanja podražaja u pamćenju prikazani distraktori različite snage (bez distraktora, slabi distraktor, snažni distraktor) s ciljem provjere interferirajućih efekata kod reprezentacija formiranih različitim količinama resursa VRP-a.

Reprezentacije različite početne kvalitete. Analiza uratka s obzirom na broj zapamćenih podražaja u kontrolnoj situaciji, kada nisu prikazani distraktirajući podražaji, pokazala je kako varijabilnost dosjećanja raste s brojem zapamćenih podražaja prema očekivanom potencijском odnosu, i to za svako od tri vremena kodiranja. Potencijски odnos rezultirat će linearnim odnosom varijabilnosti i broja upamćenih podražaja kada se prikaže na *log-log* prikazu (slika 6). Ovi rezultati pokazuju kako je, bez prikaza distraktora, broj podražaja koji se pamtio doveo do očekivane promjene u preciznosti dosjećanja, i to za sva dostupna vremena kodiranja. Na slici 7 (lijevi stupac) prikazane su distribucije dosjećanja za tri korištena vremena kodiranja i tri veličine niza koji se pamtio u situaciji kada u sekvenci nije prikazan distraktor. Uz svako dostupno vrijeme kodiranja, s porastom broja podražaja koji se pamtio distribucije postaju varijabilnije. Uloga dostupnog vremena kodiranja vidljiva je iz smanjenja varijabilnosti usporedbom distribucija unutar situacije broja podražaja koji se pamtio (lijevi stupac, promjena od prvog do trećeg retka).


Provedba analize varijance na prosječnim apsolutnim odstupanjima s faktorima vrijeme kodiranja i dužina niza (3 x 3) u situaciji kada distraktor nije prikazan pokazala je značajan



Slika 6. Odnos broja podražaja koji se pamti i varijabilnosti dosjećanja prikazan za tri korištena vremena kodiranja na *log-log* prikazu.

glavni efekt vremena kodiranja ($F(2,52) = 18.31, p < 0.001; \eta_p^2 = 0.41, BF_{inc} = 12693.7$) i glavni efekt dužine niza ($F(2,26) = 36.57, p < 0.001; \eta_p^2 = 0.74, BF_{inc} = 348874$), i neznčajnu interakciju ($F(4,52) = 2.07, p = 0.10; \eta_p^2 = 0.14, BF_{inc} = 3.1$). Naknadna testiranja uz pokazala su kako se uradak razlikuje između svih razina vremena kodiranja (svi $t \geq 3.03, p \leq 0.02; d \geq 0.56, BF_{10} \geq 7.8$) i dužine niza za pamćenje (svi $t \geq 4.07, p \leq 0.001; d \geq 0.56, BF_{10} \geq 13609$). Bayesovi faktori u svim slučajevima pokazuju snažan nalaz u prilog hipotezi kako povećanje vremena kodiranja i smanjenje dužine niza poboljšavaju uradak. Dodatna analiza razlika između dostupnih vremena kodiranja pojedinačno za svaku dužinu niza pokazala je značajan faktor vremena kodiranja unutar svake situacije dužine niza (svi $F \geq 7.46, p \leq 0.005, \eta_p^2 \geq .46, BF_{10} \geq 7.8$). Usporedba pojedinih vremena kodiranja unutar svakog niza pokazala je kako se uz dužinu niza 2 uradak ne razlikuje između 50ms i 125ms kodiranja ($t(28) = 0.36, p = 1, d = 0.12, BF_{10} = 0.34$; svi ostali $t \geq 3.36, p \leq 0.03, d \geq 1.12, BF_{10} \geq 6.4$), uz dužinu niza 4, između 125ms i 300ms kodiranja ($t(28) = 1.56, p = 0.45, d = 0.47, BF_{10} = 0.76$; svi ostali $t \geq 2.69, p \leq 0.07, d \geq 0.81, BF_{10} \geq 6.4$), te uz dužinu niza 6, između 50ms i 125ms kodiranja ($t(28) = 1.96, p = 0.26, d = 0.65, BF_{10} = 1.2$; svi ostali $t \geq 2.66, p \leq 0.09, d \geq 0.9, BF_{10} \geq 2.8$). Ukratko, unutar svakog niza pokazano je kako se uradak između najkraćeg i najdužeg vremena konzistentno razlikuje, dok se srednje vrijeme kodiranja, ovisno o broju podražaja koji se pamti ne razlikuje od najdužeg odnosno najkraćeg vremena kodiranja, iako su svi trendovi u očekivanom smjeru. Provedene analize pokazale su većinom uspješnu modulaciju preciznosti reprezentacija VRP što nam omogućava daljnje testiranje hipoteza o ulozi snage distraktora u

reprezentacijama različite kvalitete.




Slika 7. Distribucije pogrešaka dosjećanja u eksperimentu 1. U pojedinačnim prikazima nalaze se distribucije dobivene u situacijama s različitim brojem podražaja. U različitim redovima prikazane su distribucije dobivene uz različita vremena kodiranja. Pojedini stupci odgovaraju manipulaciji snage distraktora. Vrijednosti prikazane krugovima i pridruženim pogreškama odgovaraju podacima prikupljenima u eksperimentu. Linije prikazuju pristajanje testiranog modela mješovitih distribucija.

Točnost detekcije u zadatku s distraktorima. Prije provjere utjecaja interferirajućih podražaja, važno je provjeriti jesu li sudionici obraćali pažnju na interferirajući prikaz. U situaciji kada su sudionicima prikazani distraktirajući podražaji, točnost detekcije ($M \pm se$) podražaja prikazanog uz distraktore iznosila je (za 50ms i 300ms trajanja interferirajućeg prikaza): uz pamćenje 2 podražaja i 50ms vremena kodiranja $92.9\% \pm 2.8$ i $95.1\% \pm 1.7$; uz pamćenje 2 podražaja i 125ms vremena kodiranja $92.6\% \pm 2.5$ i $93.4\% \pm 2.1$; uz pamćenje 2 podražaja i 300ms vremena kodiranja $92.2\% \pm 1.5$ i $97.1\% \pm 2$; uz pamćenje 4 podražaja i 50ms vremena kodiranja $88.9\% \pm 3.1$ i $91.7\% \pm 1.9$; uz pamćenje 4 podražaja i 125ms vremena kodiranja $85.5\% \pm 3.5$ i $90.7\% \pm 2.4$; uz pamćenje 4 podražaja i 300ms vremena kodiranja $87.2\% \pm 2.8$ i $93.6\% \pm 1.6$; uz pamćenje 6 podražaja i 50ms vremena kodiranja $94.4\% \pm 1.7$ i $94.1\% \pm 2$; uz pamćenje 6 podražaja i 125ms vremena kodiranja $92.2\% \pm 2.7$ i $96\% \pm 1.7$; uz pamćenje 6 podražaja i 300ms vremena kodiranja $92.2\% \pm 3.1$ i $97.\% \pm 0.9$. Svi navedeni postoci viši su od onih koje bismo očekivali na razini slučaja te možemo zaključiti kako sudionici nisu ignorirali distraktore.

Analiza prosječnih apsolutnih odstupanja. Prvi test hipoteze o ulozi snage distraktora u reprezentacijama različite kvalitete proveden je pomoću mješovite analize varijance (3 x 3 x 3) koristeći faktore vrijeme kodiranja (50ms, 125ms, 300ms), dužina niza (2, 4, 6 podražaja) i snagu distraktora (bez distraktora, slabi distraktor, snažni distraktor) na prosječnim apsolutnim odstupanjima. Na slici 8 su prikazane vrijednosti prosječnog apsolutnog odstupanja za svaku eksperimentalnu situaciju. Provedba analize varijance pokazala je značajan efekt vremena kodiranja ($F(2,52) = 36.42, p < 0.001; \eta_p^2 = 0.58, BF_{inc} = 6.7e+11$) i dužine niza ($F(2,26) = 42.28, p < 0.001; \eta_p^2 = 0.77, BF_{inc} = 3.1e+6$). Ključno, glavni efekt pronađen je i za snagu distraktora ($F(2,52) = 31.47, p < 0.001; \eta_p^2 = 0.55, BF_{inc} = 1.4e+10$). Naknadne usporedbe između situacija snage distraktora pokazale su statistički značajne razlike između svih situacija: kontrolna i slabi distraktor ($t(28) = 4.81, p = 0.001, d = 0.89, BF_{10} = 10654$), kontrolna i snažni distraktor ($t(28) = 4.81, p < 0.001, d = 1.23, BF_{10} = 8.359e+10$), slabi i snažni distraktor ($t(28) = 3.35, p < 0.001, d = 0.62, BF_{10} = 2.8$). Pritom je uradak bio najbolji u situaciji bez distraktora, zatim u situaciji sa slabim distraktorom (50ms) i najslabiji u situaciji sa snažnim distraktorom (300ms). Ovime je potvrđen prvi dio prve hipoteze o ulozi snage distraktora u VRP-u pri čemu snažniji distraktori dovode do lošijeg uratka. Niti jedna interakcija (dvostruke niti trostruka) koja je uključivala faktor snage distraktora nije bila značajna (svi $F \leq 2.06, p \geq 0.1; \eta_p^2 \leq 0.14, BF_{inc} \leq 1.128$).

Kako bismo detaljnije ispitali ulogu snage distraktora ovisno o broju podražaja koji se pamtio provedene su pojedinačne zavisne analize varijance na faktorima vremena kodiranja i snage distraktora za svaku korištenu dužinu niza. Snaga interferencije pokazala se značajnim faktorom unutar svake dužine niza. Kod pamćenja 2 podražaja ($F(2,16) = 8.47, p = 0.003; \eta_p^2 = 0.51, BF_{inc} = 3998$) naknadne usporedbe pokazale su značajnu razliku između kontrolne situacije i slabog ($t(8) = 3.4, p = 0.028, d = 1.1, BF_{10} = 138.8$) te snažnog distraktora ($t(8) = 3.4, p = 0.028, d = 1.1, BF_{10} = 919.4$), dok se uradak uz slabe i snažne distraktore međusobno nije razlikovao ($t(8) = 0.91, p = 1, d = 0.3, BF_{10} = 0.34$). Kod pamćenja 4 podražaja ($F(2,20) = 25.57, p < 0.001; \eta_p^2 = 0.72, BF_{inc} = 2.843e+6$) naknadnim usporedbama pronađena je razlika između svih razina snage distraktora: kontrolna i slabi distraktor ($t(10) = 4.5, p = 0.003, d = 1.4, BF_{10} = 917.8$), kontrolna i snažni distraktor ($t(10) = 5.8, p < 0.001, d = 1.8, BF_{10} = 443946$), te slabi i snažni distraktor, no uz nisku razinu dokaza ($t(10) = 3.3, p = 0.02, d = 1, BF_{10} = 1.23$). Konačno, kod pamćenja 6 podražaja ($F(2,16) = 7.71, p = 0.005; \eta_p^2 = 0.49, BF_{inc} = 23.69$) naknadne usporedbe pokazale su značajnu razliku samo između kontrolne situacije i snažnog distraktora ($t(8) = 3.81, p = 0.016, d = 1.27, BF_{10} = 389.3$) dok ostale nisu pokazale značajne razlike, ali niti visoku snagu dokaza u prilog nepostojanja razlika (svi $t \leq 2.18, p \geq 0.18, d \leq 0.62, BF_{10} \leq 1.1$).

Provedba ovih analiza pokazala je značajan efekt distraktora kod svake razine niza. Prema



Slika 8. Prosječna apsolutna odstupanja u eksperimentu 1 ovisno o snazi distraktora. Različite boje odnose se na situacije pamćenja različitog broja podražaja. Nijanse iste boje odgovaraju različitim vremenima kodiranja: najsvjetlija boja 50ms, boja srednje svjetline 125ms, najtamnija boja 300ms. Za detaljnu legendu vidi sliku 9.

istraživačkoj hipotezi očekivali smo porast efekta s porastom broja podražaja koji se pamtio, odnosno padom kvalitete reprezentacija. Analiza je pokazala kako je efekt pronađen uz najveći broj podražaja za pamćenje veličinom efekta usporediv s onim pronađenim uz najmanji broj podražaja za pamćenje. Bayesov faktor neočekivano je pokazao najmanju snagu dokaza o postojanju efekta snage distraktora kod pamćenja šest podražaja. Ukratko, rezultati pokazuju kako kod najmanjeg zapamćenog broja podražaja slabi i snažni distraktori imaju podjednak efekt, što sugerira kako kod visoke preciznosti pojedinih reprezentacija, distraktori različite snage dovode do usporedivih efekata; drugim riječima, ovako ponašanje snage distraktora mogli bismo opisati kao "sve-ili-ništa". S druge strane, kod pamćenja najdužih nizova, tj. uz niske početne preciznosti, samo naj snažniji distraktori uspjeli su dodatno narušiti preciznost reprezentacija. Iako je primamljiva interpretacija ovih nalaza kako postoji svojevrsni filter koji odgovara procesima pažnje i koji funkcionira na temelju broja podražaja koji se pamti (dakle, po principima modela utora), moguće je postaviti i alternativnu hipotezu. Preciznost reprezentacija uz mali broj podražaja doseže svoj vrhunac, te bilo kakva redistribucija resursa (uključujući i slabe i snažne) distraktore može dovesti do opazivih promjena u preciznosti. S druge strane, kada je preciznost vrlo niska, moguće je kako samo snažni distraktori uspijevaju prethodno zapamćenim

podražajima oduzeti količinu resursa koja se odražava u uratku. Ipak, napomenimo još jednom kako su Bayesovi faktori koji su pratili značajne razlike uglavnom indicirali snažne dokaze o postojanju razlika; kod neznačajnih razlika, dokazi u prilog nepostojanju razlika bili su uglavnom anegdotalni. Imajući to na umu, nepostojanje nekih razlika ne bismo trebali interpretirati kao potvrdu nul hipoteze.

Konačno, željeli smo provjeriti ulogu snage distraktora u svakoj od devet situacija različitih po početnoj kvaliteti reprezentacija (3 dužine niza i 3 vremena kodiranja). Umjesto provedbe devet analiza varijance koristeći faktor snage distraktora te naknadnih testiranja, pokušali smo zahvatiti promjene u svakoj od devet situacija različitih po snazi reprezentacija. S tim ciljem, uradak svakog sudionika u svakoj situaciji dostupnog vremena kodiranja (50ms, 125ms, 300ms) procijenjen je linearnim modelom promjene u kojem je snaga distraktora predstavljala prediktor, a opažena prosječna apsolutna odstupanja kriterij. Specifičnije, linearni model procijenjen je za svaku od 9 situacija prikazanih linijama na slici 8. Ovaj model procijenjen je u dvije forme: 1) za svako vrijeme kodiranja i dužinu niza procijenjen je odsječak i nagib pravca; 2) za svako vrijeme kodiranja i dužinu niza procijenjen je odsječak, dok je nagib pravca držan fiksnim preko tri situacije vremena kodiranja. Procjene pristajanja pod oba modela bile su jednake (prosječni $r^2 = 0.56$) te je zadržan parsimoničniji model koji pretpostavlja kako je promjena uratka s obzirom na snagu distraktora jednaka za svako dostupno vrijeme kodiranja, te da su jedine razlike u inicijalnoj preciznosti reprezentacija (situacija bez distraktora). Uz svaku dužinu niza procijenjeni nagib promjene značajno se razlikovao od 0 (2 podražaja: $b = 0.027$, $t(8) = 3.4$, $p < 0.01$, $BF_{10} = 6.72$; 4 podražaja: $b = 0.065$, $t(10) = 5.8$, $p < 0.001$, $BF_{10} = 179.81$; 6 podražaja: $b = 0.068$, $t(8) = 3.8$, $p < 0.01$, $BF_{10} = 10.77$) čime je dodatno demonstrirano kako snaga distraktora značajno smanjuje uradak. Nadalje, usporedba nagiba pokazala je kako se nagib promjene kod dužine niza 2 i 4 značajno razlikuje ($t(18) = 2.69$, $p = 0.02$, $BF_{10} = 3.86$), dok se između 2 i 6 razlikuju granično uz anegdotalnu snagu dokaza ($t(16) = 2.19$, $p = 0.05$, $BF_{10} = 1.7$). Nagibi kod dužina niza 4 i 6 ($t(18) = 0.14$, $p = 0.89$, $BF_{10} = 0.4$) bili su podjednaki, uz anegdotalnu snagu dokaza u prilog nul hipotezi. Distraktori su najmanju promjenu u preciznosti, u odnosu na kontrolnu situaciju bez distraktora, prouzročili kod najkraćeg niza koji se pamtio, dok su promjene kod niza od četiri i šest podražaja bile podjednake.

Nadalje, ovi nalazi omogućuju nam da ulogu distraktora provjerimo testiranjem razlika odsječaka ovisno o broju podražaja koji se pamti i dostupnom vremenu kodiranja. Kako su nagibi promjene unutar pojedine dužine niza isti za svako dostupno vrijeme kodiranja, dovoljno je testirati razliku u odsječcima kako bismo odgovorili na pitanje razlikuju li se interferirajući efekti ovisno o početnoj kvaliteti reprezentacije VRP-a. Za svaku dužinu niza provedena je analiza varijance između vrijednosti odsječaka dobivenih za tri dostupna vremena kodiranja. Napomenimo kako bi ova analiza očekivano trebala reproducirati iste nalaze kao i prva analiza

u ovom eksperimentu, ona o uratku u kontrolnoj situaciji - odsječci koje ovdje testiramo samo su procijenjene vrijednosti prosječnih apsolutnih odstupanja u kontrolnoj situaciji pod linearnim modelom. Pronađena je značajna razlika kod pamćenja najkraćeg niza ($F(2,16) = 14.9$, $p < 0.001$; $\eta_p^2 = 0.65$, $BF_{10} = 108$) pri čemu su naknadne usporedbe pokazale kako su se uz najduže vrijeme kodiranja (300ms) sudionici dosjećali najpreciznije i to značajno u odnosu na dva kraća (svi $t \geq 4.7$, $p \leq 0.005$, $d \geq 1.6$, $BF_{10} \geq 27$), dok se najkraće (50ms) i srednje (125ms) vrijeme kodiranja ne razlikuju ($t(8) = 0.66$, $p = 1$, $d = 0.2$, $BF_{10} = 0.39$). Uz dužinu niza 4 pronadna je značajna razlika u vrijednostima odsječaka ($F(2,20) = 27.3$, $p < 0.001$; $\eta_p^2 = 0.73$, $BF_{10} = 4878.8$) te su naknadne usporedbe između svih dostupnih vremena kodiranja pokazale značajnu razliku (svi $t \geq 3.8$, $p \leq 0.003$, $d \geq 1.1$, $BF_{10} \geq 14.1$), pri čemu je dosjećanje bilo najpreciznije uz najduže, zatim uz srednje i potom uz najkraće vrijeme kodiranja. Konačno, pronadna je i značajna razlika kod sudionika koji su pamtili najduže nizove ($F(2,16) = 8.9$, $p < 0.001$; $\eta_p^2 = 0.53$, $BF_{10} = 13$) te je naknadna analiza pronašla samo jednu značajnu razliku, onu između situacije najkraćeg i najdužeg vremena kodiranja ($t(8) = 4.1$, $p = 0.01$, $d = 1.4$, $BF_{10} = 14.9$), dok se uradak uz srednje vrijeme kodiranja nije razlikovao od onog uz najkraće i najduže (svi $t \leq 2.2$, $p \geq 0.17$, $d \leq 0.73$, $BF_{10} \leq 1.6$).


U dosadašnjim analizama demonstrirali smo nekoliko važnih efekata. Prvo, kada analiziramo uradak s obzirom na broj podražaja koji se pamti i dostupno vrijeme kodiranja u situaciji kada nije prikazan distraktor, pronadna je željena modulacija u kvaliteti reprezentacija na način da uradak opada s povećanjem broja podražaja koji se pamti, ali i da se uradak razlikuje unutar svake dužine niza ovisno o dostupnom vremenu kodiranja pri čemu duža vremena kodiranja omogućavaju bolji uradak. Iako unutar nizova pojedine razlike nisu bile značajne, konzistentan je nalaz kako su dosjećanja uz najkraće vrijeme kodiranja bila lošija od dosjećanja uz najduža vremena kodiranja. Ove analize pokazale su nam kako smo uspješno stvorili situacije različite kvalitete početnih (bez distraktora) reprezentacija. Sljedeće pitanje bilo je kakve efekte će izazvati prikazivanje distraktora različite snage ovisno o opaženim početnim razlikama u kvaliteti reprezentacija. Pokazali smo kako snaga distraktora utječe na kvalitetu reprezentacija na način da snažniji distraktori dovode do lošijeg uratka od slabih distraktora, koji pak dovode do lošijeg uratka u odnosu na kontrolnu situaciju. Pokazali smo i kako nalaz o snazi distraktora vrijedi za različite kvalitete reprezentacija manipulirane brojem podražaja koji se pamtio. Ipak, efekt snage distraktora koji podrazumijeva razliku između svih razina nezavisne varijable faktora snage distraktora pronadna je samo kod pamćenja četiri podražaja; kod snažnih reprezentacija (pamćenja dva podražaja), promjene uslijed slabog distraktora bile su jednake onima uz snažni distraktor; kod najslabijih reprezentacija (pamćenje šest podražaja), samo je snažan distraktor doveo do pada u uratku.

Konačno, proširili smo ovu analizu s dužine niza na dužinu niza i dostupno vrijeme ko-

diranja. Prikazane analize u većoj su mjeri potvrdile postavljene hipoteze. Pokazali smo kako su promjene u preciznosti s porastom snage distraktora podjednake za različita vremena kodiranja, ali samo kada se promatraju unutar određenog broja podražaja koji se pamtio. Kada smo analizirali razlike u promijeni između nizova podražaja različitih dužina, pronašli smo kako do najmanje promjene dolazi kod najkraćeg niza, a do većih promjena kod pamćenja preostale dvije dužine niza (4 i 6 podražaja). Ovi rezultati su u skladu s postavljenom hipotezom. Naposljetku, pronašli smo kako su distraktori doveli do pada u uratku i to ovisno o početnoj kvaliteti reprezentacija, na način da je duže vrijeme kodiranja, neovisno o broju podražaja koji se pamtio, dovelo do formiranja preciznijih reprezentacija, koje su nakon prezentacije distraktora ostale preciznije od reprezentacija formiranih u kraće vrijeme. Važno je napomenuti, linearni model koji pretpostavlja kako su promjene za svako vrijeme kodiranja bile jednake unutar pojedine situacije broja zapamćenih podražaja pokazao je jednako dobro pristajanje kao i model koji pretpostavlja da su sve promjene sa snagom distraktora specifične za pojedinu kombinaciju dužine niza i dostupnog vremena kodiranja. Dio rezultata koji nije u skladu s hipotezama odnosi se na činjenicu da nismo pronašli značajne razlike u preciznosti dosjećanja, a onda niti u promjenama u preciznosti uslijed distraktora između svakog korištenog vremena kodiranja unutar pojedine situacije broja pamćenih podražaja. Konkretno, samo su se uz četiri upamćena podražaja dosjećanja uz sva korištena vremena međusobno razlikovala, dok se uz pamćenje dva odnosno šest podražaja najduže vrijeme isticalo od preostala dva kao vrijeme kodiranja uz koje je postignuta najbolja preciznost koja je i uslijed prikaza distraktora ostala bolja od preciznosti opaženih uz kraća vremena kodiranja. Kako je ovaj rezultat opažen i u kontrolnoj situaciji bez distraktora, on više govori o odabiru vremena kodiranja nego o efektu distraktora. Konkretno, kako potpuna modulacija preciznosti dosjećanja uz dva i šest podražaja nije ostvarena korištenjem najkraćeg i srednjeg vremena kodiranja u kontrolnoj situaciji, bilo je teško očekivati pronalazak značajnih razlika jednom kada se distraktori uključe. Ukupno gledano, dosadašnje analize pokazale su kako snaga distraktora mijenja pogreške dosjećanja očekivano, ovisno o snazi početnih reprezentacija.

Model mješovitih distribucija. Kako bismo podrobnije razmotrili izvore opaženih promjena u uratku, procijenjeno je pristajanje modela mješovitih distribucija podacima. Konkretno, ovaj model pretpostavlja kako je uradak u ovom eksperimentu moguće opisati parametrima točnih dosjećanja, slučajnog pogađanja, pogrešnih zamjena i intruzija. Pristajanje ovog modela uspoređeno je s parsimoničnijim modelom koji pretpostavlja kako se uradak može opisati točnim dosjećanjima i slučajnim pogađanjima. Usporedba modela favorizirala je kompleksniji model i u kontrolnoj situaciji (model bez intruzija: $\Delta AIC = 148.59$, $t(28) = 2.62$, $p = 0.01$) i u dvije situacije prikazivanja distraktora (puni model: $\Delta AIC = 272.4$, $t(28) = 2.1$, $p = 0.04$). Puni model uspješno je reproducirao distribucije pogrešaka dosjećanja (linije na slici 7) te prosječna apsolutna odstupanja ($r^2 = 0.9 \pm 0.016$). Parametri najbolje pristajućeg modela prikazani su

ovisno o eksperimentalnoj manipulaciji na slici 9.



Slika 9. Parametri modela mješovitih distribucija u eksperimentu 1 u funkciji snage distraktora, broja podražaja koji se pamti i dostupnog vremena kodiranja. a) vjerojatnost točnih dosjećanja; b) preciznost dosjećanja; c) vjerojatnost pogađanja; d) vjerojatnost pogreške zamjene; e) vjerojatnost intruzija.

Sljedeći korak bio je provedba niza složenih (3 x 3 x 3) analiza varijance pri čemu su parametri modela mješovitih distribucija predstavljali zavisne varijable. Prilikom testa razlika u parametrima modela između eksperimentalnih situacija, usmjerili smo se samo na situacije koje uključuju manipulaciju snagom distraktora (glavni efekti i interakcije). Vjerojatnost točnog dosjećanja (slika 9a) varirala je u funkciji snage interferencije ($F(2,52) = 18.03, p < 0.001, \eta_p^2 = 0.41, BF_{inc} = 75216$), a naknadne usporedbe pronašle su razliku između kontrolne situacije te slabih ($t(28) = 3.98, p < 0.001, d = 0.74, BF_{10} = 122.3$) i snažnih ($t(28) = 5.12, p < 0.001, d = 0.74, BF_{10} = 196399$) distraktora, pri čemu su vjerojatnosti točnog dosjećanja bile više u kontrolnoj situaciji. Slabi i snažni distraktori nisu međusobno razlikovali ($t(28) = 2.23, p = 0.1, d = 0.41, BF_{10} = 0.43$). Dvostruke interakcije (svi $F \leq 2.07, p \geq 0.1, \eta_p^2 \leq 0.14, BF_{inc} \leq 0.8$) kao niti trostruka interakcija ($F(8,104) = 0.47, p = 0.88, \eta_p^2 = 0.04, BF_{inc} = 0.01$) snage distraktora s dužinom niza i vremenom kodiranja nisu pokazale značajne efekte. Kod testiranja unutar pojedinačnih dužina nizova, nisu pronađene razlike u vjerojatnosti dosjećanja s obzirom na snagu distraktora kod najkraćeg niza ($F(2,16) = 2.61, p = 0.1, \eta_p^2 = 0.25, BF_{inc} = 1.4$). Kod

pamćenja 4 podražaja pronađena je značajna razlika ($F(2,20) = 13.69$, $p < 0.001$, $\eta_p^2 = 0.58$, $BF_{inc} = 859.4$), a naknadna testiranja pronašla su kako u odnosu na kontrolnu situaciju pada vjerojatnost točnog dosjećanja nakon prikaza slabih distraktora ($t(10) = 3.2$, $p = 0.03$, $d = 0.97$, $BF_{10} = 9.1$), te snažnih distraktora ($t(10) = 4.5$, $p = 0.003$, $d = 1.4$, $BF_{10} = 894.4$), dok se utjecaj slabih i snažnih distraktora nije razlikovao ($t(10) = 2.4$, $p = 0.112$, $d = 0.72$, $BF_{10} = 1$). Konačno, kod najdužih nizova pronađen je značajan efekt snage distraktora, ali uz snagu dokaza koju možemo smatrati anegdotalnom ($F(2,16) = 5.12$, $p = 0.02$, $\eta_p^2 = 0.39$, $BF_{inc} = 2.9$). Naknadne analize pokazale su graničnu razliku između kontrolne situacije i najsnažnijih distraktora ($t(8) = 2.8$, $p = 0.07$, $d = 0.95$, $BF_{10} = 11.17$) ali uz relativno snažan dokaz, sugerirajući kako vjerojatnost točnog dosjećanja pada nakon prikaza snažnih distraktora (ostali $t \leq 2.3$, $p \geq 0.15$, $d \leq 0.76$, $BF_{10} \leq 1.5$). U skladu s postavljenom hipotezom pronašli smo efekt snage distraktora na vjerojatnost točnog dosjećanja. Nadalje, također u skladu s hipotezom ovaj efekt bio je izraženiji uz veći broj podražaja koji se pamtio, tj. slabijom snagom reprezentacija podražaja u VRP-u. Ipak, ovaj efekt nismo uspjeli potvrditi u potpunosti kod četiri i šest pamćenih podražaja; kod pamćenja četiri podražaja, distraktori različite snage se nisu razlikovali u interferirajućem efektu, dok je kod najdužeg niza, samo najsnažniji distraktor doveo do interferirajućeg efekta.

Testiranjem parametra preciznosti dosjećanja (slika 9b) (κ parametar modela) nije pronađen značajan glavni efekt ($F(2,52) = 0.29$, $p = 0.75$, $\eta_p^2 = 0.01$, $BF_{inc} = 0.02$), te niti jedna interakcija (svi $F \leq 1.3$, $p \geq 0.23$, $BF_{inc} \leq 0.008$). Ovi rezultati snažno sugeriraju kako se preciznost dosjećanja ne mijenja uslijed prikaza distraktora. Sljedeće pitanje na koje smo htjeli odgovoriti jest jesu li sudionici zaboravili podražaj koji se tražio za dosjećanje, jesu li zabunom naveli neki drugi podražaj koji su zapamtili, ili je distraktor izbrisao i zamijenio reprezentaciju traženog podražaja. Prva analiza usmjerila se na parametar slučajnih pogađanja (slika 9c). Nakon provedbe složene analize varijance pronađeno je kako podaci sugeriraju o nepostojanju glavnog efekta snage distraktora ($F(2,52) = 2.05$, $p = 0.14$, $\eta_p^2 = 0.07$, $BF_{inc} = 0.13$), te samo granično značajnoj interakciji snage distraktora i broja podražaja koji se pamtio ($F(4,52) = 2.55$, $p = 0.05$, $\eta_p^2 = 0.16$, $BF_{inc} = 0.3$), a koja je dominantno proizašla iz gotovo nultog pogađanja uz najkraću dužinu niza te nesistematskog variranja ovog parametra uz četiri i šest podražaja za pamćenje. Napomenimo kako je Bayesov faktor pokazao umjerenu snagu dokaza za isključivanjem ovog interakcijskog efekta iz modela.

Analizom varijance na parametru vjerojatnosti pogrešaka zamjena (slika 9d) pronađen je granični efekt snage distraktora ($F(2,52) = 2.05$, $p = 0.05$, $\eta_p^2 = 0.11$, $BF_{inc} = 0.27$), no uz vrlo nisku razinu dokaza i to u smjeru nepostojanja razlika između skupina. U skladu s tim, provedba naknadnih testova pokazala je granični porast vjerojatnosti pogreške zamjena u odnosu na kontrolnu situaciju uslijed prikaza slabih ($t(28) = 2.35$, $p = 0.08$, $d = 0.44$, $BF_{10} = 1.86$) i

snažnih distraktora ($t(28) = 2.44$, $p = 0.06$, $d = 0.45$, $BF_{10} = 1.57$). Analize snage distraktora na nizovima pojedine dužine nisu otkrile značajno djelovanje snage distraktora (svi $F \leq 1.87$, $p \geq 0.19$, $\eta_p^2 \leq 0.19$, $BF_{inc} \leq 0.33$). Suprotno očekivanjima, prikaz distraktora nije doveo do porasta pogrešaka zamjene.

Posljednji analizirani izvor pogrešaka bile su intruzije distraktora u VRP (slika 9e). Do sada smo parametre uspoređivali u odnosu na kontrolnu situaciju, no intruzije su bile moguće samo u situacijama prikaza distraktora, te ćemo njih za početak testirati t testom za jedan uzorak kako bismo provjerili razlikuju li se od 0. Ova analiza pokazala je kako su vjerojatnosti dosjećanja distraktora bile značajno više od 0 i uslijed slabih distraktora ($t(28) = 5.1$, $p < 0.001$, $d = 0.95$, $BF_{10} = 1081.8$) i uslijed snažnih distraktora ($t(28) = 4.76$, $p < 0.001$, $d = 0.88$, $BF_{10} = 460.2$). Usporedbom situacija slabih i jakih distraktora nije pronađena razlika u vjerojatnosti intruzija ($t(28) = 0.16$, $p = 0.88$, $d = 0.03$, $BF_{10} = 0.2$). Značajna proporcija intruzija (> 0) uslijed slabih i jakih distraktora pronađena je i za svaku dužinu niza zasebno (svi $t \geq 2.77$, $p \leq 0.02$, $d \geq 0.93$, $BF_{10} \geq 3.18$). S porastom broja podražaja koji se pamtio rasla je proporcija intruzija kod slabih distraktora ($F(2,26) = 8.06$, $p = 0.002$, $\eta_p^2 = 0.38$, $BF_{inc} = 19.59$), pri čemu su intruzije bile znatno češće kod najdužeg u odnosu na najkraći niz ($t(28) = 3.8$, $p = 0.002$, $d = 1.7$, $BF_{10} = 13.77$) te u odnosu na srednji niz ($t(28) = 3.05$, $p = 0.014$, $d = 1.18$, $BF_{10} = 3.48$). Isti efekt dužine niza potvrđen je i kod jakih distraktora ($F(2,26) = 4.79$, $p = 0.017$, $\eta_p^2 = 0.27$, $BF_{inc} = 3.56$), pri čemu su intruzije bile znatno češće kod najdužeg niza samo u odnosu na najkraći niz ($t(28) = 3.04$, $p = 0.014$, $d = 1.2$, $BF_{10} = 3.76$; preostali $t \leq 2.07$, $p \geq 0.12$, $d \leq 0.81$, $BF_{10} \leq 1.2$). Kada smo testirali razlikuju li se proporcije intruzija od 0 i za svako vrijeme kodiranja unutar pojedine dužine niza, pritom uzimajući u obzir i snagu distraktora, pronašli smo kako te proporcije pokazuju uglavnom granične vrijednosti te s time očekivano i nisku razinu dokaza kod najkraćeg niza (svi $1.66 \leq t \leq 2.16$, $0.06 \leq p \leq 0.14$, $0.55 \leq d \leq 0.72$, $0.89 \leq BF_{10} \leq 1.6$) dok su konzistentno niže p vrijednosti i snažniji nalazi u prilog hipotezi o razlici pronađeni kod dužine nizova 4 (svi $1.9 \leq t \leq 3.1$, $0.01 \leq p \leq 0.08$, $0.58 \leq d \leq 0.93$, $1.2 \leq BF_{10} \leq 5.4$) te dužine nizova 6 (svi $2.4 \leq t \leq 5.04$, $0.001 \leq p \leq 0.04$, $0.82 \leq d \leq 1.68$, $2.22 \leq BF_{10} \leq 40.98$; uz iznimku snažnog distraktora uz najduže vrijeme kodiranja $t(8) = 1.79$, $p = 0.1$, $d = 0.6$, $BF_{10} = 1$). Konačno, provedba analize varijance ($3 \times 3 \times 2$) s faktorima dužine niza, vremena kodiranja te snage distraktora (na dvije razine, bez kontrolne situacije) pokazala je sada već očekivano neznačajan glavni efekt snage distraktora ($F(1,26) = 0.01$, $p = 0.91$, $\eta_p^2 = 0.001$, $BF_{inc} = 0.8$), kao i interakcije koje su uključivale faktor snage distraktora (svi $F \leq 1.17$, $p \geq 0.32$, $\eta_p^2 \leq 0.043$, $BF_{inc} \leq 0.04$).

Provjera pristajanja modela mješovitih distribucija opaženim podacima pokazala je kako hipotetizirani, kompleksniji model bolje pristaje podacima od alternativnog "sve-ili-ništa" modela. Prema hipotetiziranom, i prihvaćenom, modelu dosjećanje se može opisati različitim vr-


stama odgovora: točnim dosjećanjima, slučajnim pogađanjem, pogreškama zamjene i intruzijama. Provedena usporedba modela pokazuje kako pogreške zamjene i intruzije (dva parametra koja nedostaju jednostavnom modelu) predstavljaju važne izvore pogrešaka u zadacima VRP. Kako bismo provjerili možemo li prethodno opažene promjene kod prosječnih apsolutnih odstupanja opisati jednako sustavnim promjenama na nekom od parametara ovog modela, proveden je niz složenih analiza varijance u kojima je pojedini parametar modela predstavljao zavisnu varijablu. Ukratko, jedino je vjerojatnost točnog odgovaranja pokazala sustavne promjene sa snagom distraktora. Kod najkraćeg niza, distraktori nisu doveli do pada vjerojatnosti točnih dosjećanja. Kod pamćenja četiri podražaja, slabi i snažni distraktor razlikovali su se od kontrolne situacije ali ne i međusobno; kod pamćenja šest podražaja, kontrolna i slabi distraktor razlikovali su se od snažnog distraktora, ali ne i međusobno. Drugim riječima, kod najkraćih nizova, vjerojatnost točnih dosjećanja nije se mijenjala ovisno o snazi distraktora, a ovaj nalaz donekle je očekivan s obzirom na najmanji pronađeni utjecaj snage distraktora na prosječno apsolutno odstupanje kod najkraćih nizova. Kod najdužih nizova ponovno se pokazalo kako samo snažan distraktor može dovesti do promjena koje su opazive. Kako su vjerojatnosti pojedine distribucije u modelu mješovitih distribucija u negativnoj, ali očekivano visokoj korelaciji, očekivali smo kako će se efekti opaženi na vjerojatnosti točnih dosjećanja odraziti na neki od preostalih vjerojatnosti. Uostalom, pad u vjerojatnosti točnog dosjećanja pokazuje kako su sudionici griješili, ali ne otkriva kako su griješili. Međutim, analiza slučajnog pogađanja i pogrešaka zamjene nije pokazala značajne promjene sa snagom distraktora. Ovaj nalaz posebno je zanimljiv za procjene pogrešaka zamjene jer pokazuje kako prikazivanje distraktora nije unosilo dodatan šum u povezivanje boja podražaja s njihovim lokacijama, što se tipično smatra dominantnim uzrokom nastanka ovih pogrešaka (Schneegans i Bays, 2016, 2017a). Konačno, intruzije procijenjene u situacijama slabih i snažnih distraktora pokazale su varijabilnost s brojem podražaja koji se pamtio pri čemu su te proporcije uz pamćenje najkraćih nizova bile vrlo niske, te značajno više uz najduži niz za pamćenje. Važno je napomenuti kako se proporcije intruzija nisu razlikovale ovisno o snazi distraktora. Ovaj nalaz vrlo je zanimljiv jer pokazuje kako distraktori različite snage imaju podjednaku vjerojatnost biti kodirani u VRP-e. Važno je napomenuti kako ovaj nalaz ipak ne govori da snaga distraktora nema ulogu u funkcioniranju VRP-a - distraktori različite snage, kao što smo i pokazali, mogu dovesti do različitog porasta pogreške dosjećanja (prosječna apsolutna odstupanja).

5.2 Eksperiment 2a

U 2a eksperimentu željeli smo provjeriti može li davanje prednosti, odnosno prioriteta određenom podražaju za dosjećanje zaštititi reprezentaciju tog podražaja od interferencije, te kakve su posljedice davanja prioriteta jednom podražaju na preostale, neprioritetne podražaje. U tu svrhu

u zadatku VRP-a s pamćenjem boja tijekom faze zadržavanja signalizirali smo jedan od prethodno prikazanih podražaja kao podražaj koji ima najveću vjerojatnost dosjećanja. Prilikom dosjećanja, u 75% slučajeva tražili smo od sudionika da se dosjete signaliziranog podražaja (prioritetni podražaj), a u ostatku sekvenci da se dosjete jednog od neprioritetnih (nesignaliziranih) podražaja. Konačno, ponovno smo manipulirali snagom distraktora s ciljem provjere jesu li prioritetne i neprioritetne reprezentacije različito osjetljive na distraktore različite snage.

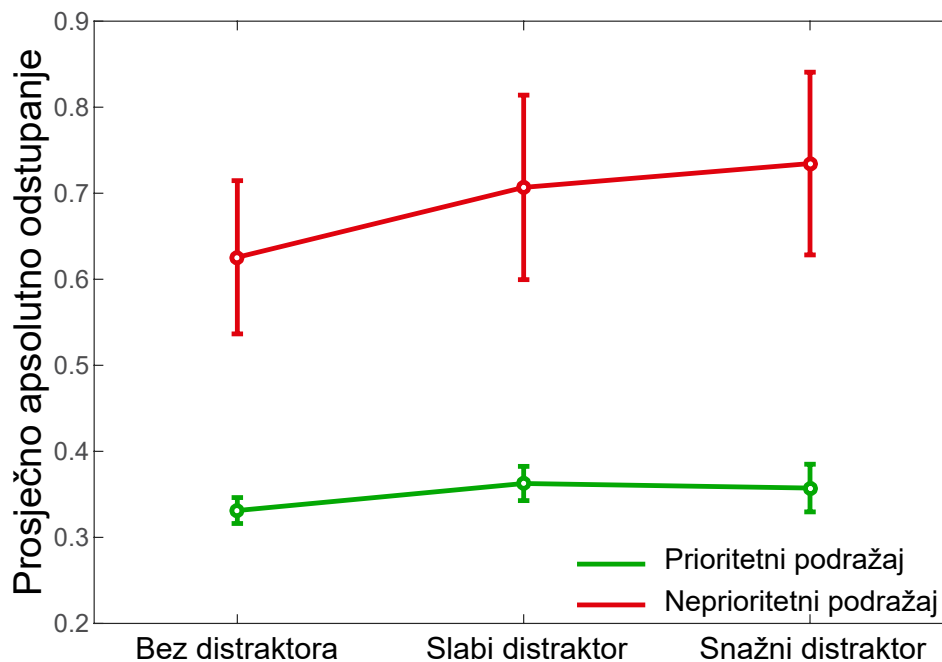
Uradak u kontrolnoj situaciji. Prije testa naših hipoteza, provjeren je uradak sudionika u sekvencama u kojima nije prikazan distraktor. Na slici 10 prikazane su distribucije pogrešaka dosjećanja prioritetnih (sudionici su se stvarno dosjećali podražaja koji je označen kao prioritet) i neprioritetnih (sudionici su se dosjećali jednog od preostalih podražaja od kojih niti jedan nije označen kao prioritet) podražaja u situaciji bez distraktora. Vidljivo je kako je distribucija pogrešaka znatno varijabilnija u sekvencama kada su se sudionici dosjećali podražaja koji prethodno nije bio prioritetiziran za dosjećanje. Ovo je potvrdio i t test pokazavši statistički značajno viša prosječna apsolutna odstupanja na neprediktivnim sekvencama ($t(11) = 3.4, p = 0.006, d = 0.99, BF_{10} = 9.52$).



Slika 10. Distribucije pogrešaka dosjećanja u eksperimentu 2a. U različitim redovima prikazane su distribucije dobivene kod dosjećanja prioritetnog (gore) i neprioritetnog (dolje) podražaja. Pojedini stupci odgovaraju manipulaciji snage distraktora. Vrijednosti prikazane crnim krugovima i pridruženim pogreškama odgovaraju podacima prikupljenima u eksperimentu. Obojene linije prikazuju pristajanje testiranog modela mješovitih distribucija.

Točnost detekcije u zadatku s distraktorima. Sudionici su u sve četiri situacije detektirali ciljni podražaj prikazan uz distraktore iznad razine slučaja ($M \pm se$ za slabe i snažne distraktore): kod dosećanja prioritetnih podražaja $88.1\% \pm 2.9$ i $89.5\% \pm 1.9$; kod dosećanja neprioritetnih podražaja $85.7\% \pm 3.2$ i $92.3\% \pm 1.7$.

Analiza prosječnih apsolutnih odstupanja. Provedena je složena analiza varijance (3 x 2) za ponovljena mjerenja na prosječnim apsolutnim odstupanjima koristeći faktore snage distraktora (kontrolna, slabi, snažni) i prioriteta za dosjećanje (prioritetan, neprioritetan) (slika 11). Pronađen je značajan glavni efekt snage distraktora ($F(2,22) = 3.5$, $p = 0.05$, $\eta_p^2 = 0.24$, $BF_{inc} = 0.18$) iako je Bayesov faktor sugerirao tek umjerenu snagu dokaza i to u smjeru isključivanja faktora. U skladu s tim naknadni testovi nisu pronašli niti jednu značajnu razliku testirajući parove razina faktora snage distraktora, izuzev granične značajnosti kontrolne situacije i slabog distraktora (svi $t \leq 2.7$, $p \geq 0.06$, $d \leq 0.78$, $BF_{10} \leq 4.1$). Detaljnijim testiranjem ovog efekta provedbom jednostavnih analiza varijance odvojeno za dosjećanje prioritetnih i neprioritetnih podražaja potvrđeno je nepostojanje efekta snage distraktora (svi $F \leq 2.8$, $p \geq 0.08$, $\eta_p^2 = 0.21$, $BF_{10} \leq 1.1$). Pronađen je i značajan glavni efekt prioriteta ($F(1,11) = 12.44$, $p = 0.005$, $\eta_p^2 = 0.53$, $BF_{inc} = 1.138e+7$) koji je odražavao bolje dosjećanje za prioritetne podražaje, te neznačajna interakcija ($F(2,22) = 1.44$, $p = 0.26$, $\eta_p^2 = 0.12$, $BF_{inc} = 0.16$).



Slika 11. Prosječna apsolutna odstupanja u eksperimentu 2a ovisno o snazi distraktora i prioritetu podražaja za dosjećanje.


Rezultati ovog istraživanja su pokazali kako distraktori ne narušavaju preciznost podražaja koji je prioritetan za dosjećanje. Neovisno o snazi distraktora, sudionici su se signaliziranih odnosno prioritetiranih podražaja dosjećali jednako dobro kao i kada distraktora nije bilo. Osim toga, nije pronađen niti efekt distraktora kada su se sudionici dosjećali podražaja koji nije bio signaliziran (neprioritetan podražaj). Podsjetimo, postavljena istraživačka hipoteza bila je kako će distraktori dovesti do veće pogreške kod neprioritetnih, ali ne i prioritetnih podražaja. Samim time, naša hipoteza je djelomično potvrđena. Međutim, važno je napomenuti kako snaga

dokaza u prilog nul hipotezi o nepostojanju razlika spada u anegdotalne nalaze. Ipak, ako prihvatimo ove rezultate, oni nam govore kako prioritiziran podražaj ima zaštićen status u VRP-u. Prethodna istraživanja pokazala su kako je podražaj kojem je dan prioritet za dosjećanje zaštićen od osipanja (Pertzov i sur., 2013, 2017), interferencije od preostalih zapamćenih podražaja (Hollingworth i Maxcey-Richard, 2013; Makovski i Pertzov, 2015), te interferenciju prilikom davanja odgovora (Astle i sur., 2012; Makovski i sur., 2008; Matsukura i sur., 2007; Souza i sur., 2016) dok ovo istraživanje pokazuje i kako to vrijedi za perceptivne distraktore.

Prioritiziranje predstavlja i više nego plauzibilan zaštitni mehanizam, no kako možemo objasniti činjenicu da distraktori nisu djelovali na nesignalizirane podražaje? Jedna mogućnost je da su u trenutku davanja prioriteta signaliziranom podražaja dolazi do naglog zaustavljanja bilo kakvog zaštitnog mehanizma koji bi inače štutio podražaje od osipanja i interferencije od strane drugih zapamćenih podražaja, te da time kvaliteta reprezentacija naglo pada, i to do razine kod koje dodatno prikazivanje distraktora ne narušava reprezentacije. Važno je napomenuti kako su se prosječna apsolutna odstupanja dosjećanja neprioritetnih podražaja značajno razlikovala od onih koje bismo očekivali uz slučajno odgovaranje (svi $t \geq 7.2$, $p < 0.001$, $d \geq 2.1$, $BF_{10} \geq 653$), zbog čega interpretacija u smjeru strogog ograničenja raspona nakon kojeg je nemoguće mijenjati reprezentaciju nije plauzibilna. Moguća hipoteza je i kako se mjesto pohrane neprioritetnih podražaja seli u područja mozga u kojima distraktori kodirani u senzornim područjima nemaju utjecaj. U skladu s takvom hipotezom je nedavno istraživanje Christophel i sur. (2018) koje je pokazalo kako su nesignalizirani podražaji reprezentirani u intraparietalnom području i prednjem očnom području. Lewis-Peacock i sur. (2018) predložili su mehanizam privremenog izbacivanja podražaja koji nemaju prioritet za dosjećanje. Iako je ova hipoteza, iz perspektive modela resursa, malo vjerojatna, ona pretpostavlja kako pohrana neprioritetnih podražaja ovisi o dugoročnom pamćenju, čime bi ti podražaji mogli biti zaštićeni od perceptivnih distraktora. Na kraju ove kratke rasprave, važno je još jednom ponoviti kako su se Bayesovi faktori vezani uz analizu snage distraktora, neovisno o analizi pokazivali nisku razinu snage dokaza, pri čemu nije prevladala količina dokaza niti u smjeru jedne hipoteze odnosno uključivanja ili isključivanja faktora u model. Kako bismo prihvatili ili odbacili hipotezu o ulozi snage distraktora ovisno o davanju i oduzimanju prednosti podražajima za dosjećanje, potrebna su dodatna istraživanja.

Model mješovitih distribucija. Provjereno je pristajanje modela mješovitih distribucija prema kojem se uradak u zadatku može opisati točnim dosjećanjima, slučajnim pogađanjima, pogreškama zamjene i intruzijama. Ponovno, ovaj model uspoređen je s jednostavnijim modelom prema kojem sudionici ili pamte ili ne pamte (slučajno pogađaju) kvalitetu podražaja. U kontrolnoj situaciji, bez distraktora, puni model pretpostavlja dosjećanja iz tri distribucije (bez intruzija) i takav model pokazao je bolje pristajanje podacima ($\Delta AIC = 112.7$, $t(11) = 1.19$, p

= 0.26). U situacijama prikazivanja distraktora, kompleksniji, ujedno i hipotetizirani, model ponovno je pokazao superiornije pristajanje podacima u odnosu na jednostavniji model ($\Delta AIC = 154.8$, $t(11) = 1.05$, $p = 0.32$). Kompleksniji model uspješno je reproducirao opažene distribucije pogrešaka dosjećanja (linije na slici 10) kao i prosječna apsolutna odstupanja ($r^2 = 0.95 \pm 0.019$). Parametri najbolje pristajućeg modela prikazani su na slici 12.



Slika 12. Parametri modela mješovitih distribucija u eksperimentu 2a u funkciji snage distraktora i prioriteta podražaja. a) vjerojatnost točnih dosjećanja; b) preciznost dosjećanja; c) vjerojatnost pogađanja; d) vjerojatnost pogreške zamjene; e) vjerojatnost intruzija.

Sljedeći korak sastojao se u provedbi niza složenih (3 x 2) analiza varijance za ponovljena mjerenja s faktorima snage distraktora i prioriteta za dosjećanje s ciljem provjere pokazuje li neki od parametara modela specifične promjene uslijed prikaza distraktora. Analiza parametra vjerojatnosti točnih dosjećanja (slika 12a) pokazala je neznačajan glavni efekt snage distraktora ($F(2,22) = 1.77$, $p = 0.19$, $\eta_p^2 = 0.14$, $BF_{inc} = 0.14$), ali značajan glavni efekt prioriteta ($F(1,11) = 11.65$, $p = 0.006$, $\eta_p^2 = 0.51$, $BF_{inc} = 4.225e+6$) na način da su prioritetni podražaji imali značajno višu vjerojatnost točnog dosjećanja. Interakcija snage distraktora i prioriteta nije bila značajna ($F(2,22) = 1.2$, $p = 0.31$, $\eta_p^2 = 0.1$, $BF_{inc} = 0.1$). Iako trend rezultata sugerira smanjenje vjerojatnosti točnih dosjećanja s porastom snage distraktora kod dosjećanja neprioritetnih podražaja, provedba jednostavne ANOVAe nije pokazala značajan efekt ($F(2,22) = 1.58$, $p = 0.23$, $\eta_p^2 = 0.13$, $BF_{10} = 0.52$). Znatno niže razine točnih dosjećanja neprioritetnih podražaja značio je porast vjerojatnosti nekih od pogrešaka. Analizom vjerojatnosti slučajnog pogađanja

(slika 12c) glavni efekt snage distraktora ponovno nije bio značajan ($F(2,22) = 0.02$, $p = 0.98$, $\eta_p^2 = 0.001$, $BF_{inc} = 0.1$), dok su sudionici znatno više pogađali prilikom dosjećanja neprioritetnih podražaja ($F(1,11) = 10.9$, $p = 0.007$, $\eta_p^2 = 0.5$, $BF_{inc} = 254.3$). Interakcija dva faktora nije bila značajna ($F(2,22) = 0.23$, $p = 0.8$, $\eta_p^2 = 0.01$, $BF_{inc} = 0.09$). Vjerojatnost pogrešaka zamjena pokazala je isti obrazac rezultata, na način da je izostao glavni efekt snage distraktora ($F(2,22) = 0.26$, $p = 0.78$, $\eta_p^2 = 0.02$, $BF_{inc} = 0.1$), dok je glavni efekt prioriteta pokazao graničnu značajnost ali i visoku snagu dokaza u korist hipoteze o razlici ($F(1,11) = 4.1$, $p = 0.07$, $\eta_p^2 = 0.027$, $BF_{inc} = 342$). Interakcija je i kod ovog parametra bila neznačajna ($F(2,22) = 0.46$, $p = 0.64$, $\eta_p^2 = 0.04$, $BF_{inc} = 0.08$).

Posljednji izvor pogrešnih dosjećanja predstavljale su intruzije (slika 12e). Prvi korak bila je provjera razlikuju li se vrijednosti ovih parametara od 0. Sve četiri procijenjene vjerojatnosti bile su značajno više od 0 (svi $t \geq 2.7$, $p \leq 0.02$, $d \geq 0.77$, $BF_{10} \geq 3.2$). Analiza varijance ponovno je pokazala neznačajan glavni efekt snage distraktora ($F(1,11) = 0.01$, $p = 0.79$, $\eta_p^2 = 0.01$, $BF_{inc} = 0.27$) te značajan glavni efekt prioriteta ($F(1,11) = 6.6$, $p = 0.03$, $\eta_p^2 = 0.38$, $BF_{inc} = 3.2$) uz neznačajnu interakciju ($F(1,11) = 0.35$, $p = 0.56$, $\eta_p^2 = 0.03$, $BF_{inc} = 0.3$). Konačno, provedba analize varijance na parametru preciznosti dosjećanja (slika 12b) nije pokazala niti značajne glavne efekte snage distraktora ($F(2,22) = 0.27$, $p = 0.77$, $\eta_p^2 = 0.02$, $BF_{inc} = 0.1$) i prediktivnosti ($F(1,11) = 0.73$, $p = 0.4$, $\eta_p^2 = 0.06$, $BF_{inc} = 0.26$) kao niti njihovu interakciju ($F(2,22) = 0.2$, $p = 0.82$, $\eta_p^2 = 0.02$, $BF_{inc} = 0.03$).

U eksperimentu 2a ispitana je uloga davanja prioriteta podražaju za dosjećanje pri čemu su sudionici, kao optimalnu strategiju obavljanja zadatka, trebali zaštititi signaliziranu reprezentaciju i istovremeno zaustaviti aktivno ili spontano održavanje preostalih reprezentacija. Davanje prioriteta podražaju za dosjećanje korištenjem visoko prediktivnih signala djeluje kao trajna (do kraja sekvence, tj. obavljanja zadatka) odrednica upravljanja reprezentacijama, te je ovo istraživanje pokazalo kako određivanje prioriteta za dosjećanje djeluje protektivno na preciznost dosjećanja, čak i uslijed prikaza distraktora. U skladu s postavljenom hipotezom, model mješovitih distribucija dobro je pristajao podacima i pokazao kako su pogreške zamjena i intruzije važna komponenta dosjećanja uslijed prikaza distraktora. Testiranjem parametara modela nije pronađeno sustavno variranje niti jednog od parametara s promjenom snage distraktora. Izuzev pogrešaka intruzija koje nije bilo moguće opaziti u kontrolnoj situaciji, svi parametri procijenjeni u situacijama s distraktorima bili su usporedivi onima opaženima u kontrolnoj situaciji. Istovremeno, neprioritetni podražaji također nisu bili pod utjecajem distraktora, iako pod cijenu lošijeg dosjećanja čak i kad nije bilo distraktora (opaženi glavni efekt prioriteta). Ovakav ishod modeliranja u skladu je s prethodno opaženim stabilnostima prosječnih apsolutnih odstupanja neovisno o prikazu distraktora.

Osim ovakvog trajnog određivanja prioriteta, dinamična okolina u kojoj tipično obavljamo

zadatak obiluje i *odozdo-prema-gore* signalima uslijed kojih neki podražaji mogu biti istaknuti tijekom faze zadržavanja, pri čemu njihova relevantnost za obavljanje zadatka ostaje jednaka preostalim podražajima. U eksperimentu 2b pokušali smo odgovoriti kako privremeno dovode-nje podražaja u fokus pažnje, tzv. osvježavanje, utječe na zaštitu podražaja od distraktora.

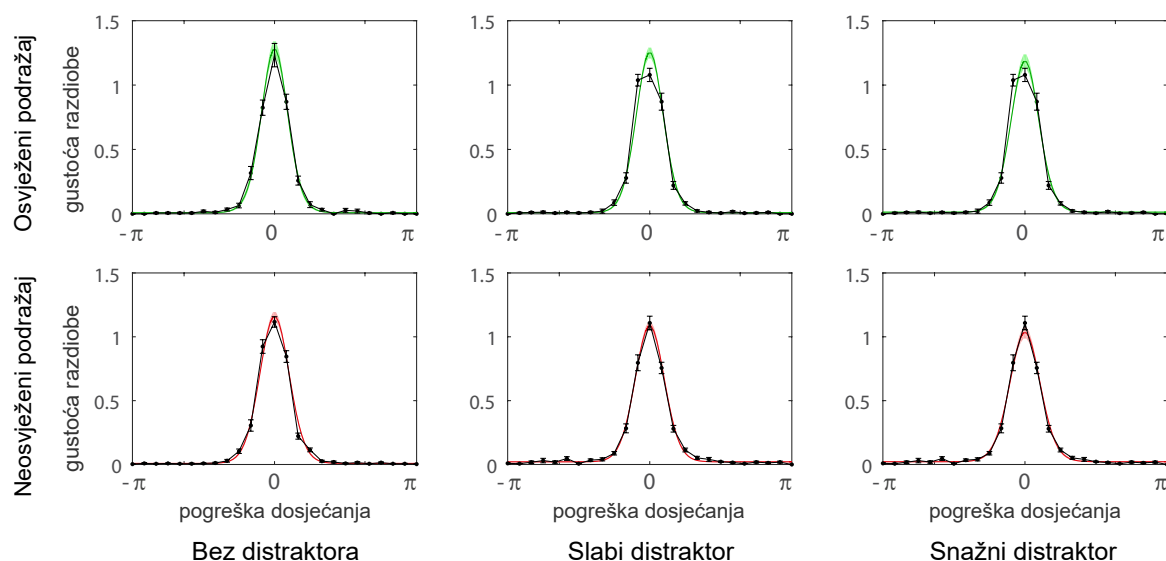
5.3 Eksperiment 2b

U eksperimentu 2a željeli smo provjeriti kakvu ulogu neinformativno signaliziranje, tj. signali neprediktivni za dosjećanje, imaju u zaštiti reprezentacija VRP-a od distraktora. Eksperiment 2b po svim karakteristikama odgovarao je eksperimentu 2a, uz izuzetak korisnosti signala za dosjećanje. U eksperimentu 2b, signal prikazan tijekom faze zadržavanja nije bio prediktivan za dosjećanje. Na taj način, uključivanje bilo kakvog mehanizma *odozgo-prema-dolje* ne bi predstavljalo adaptivnu strategiju rješavanja zadatka. Imajući to na umu, prikazani signali vje-rojatnije su angažirali mehanizme *odozdo-prema-gore* i privremeno doveli signalizirani podra-žaj u fokus pažnje i osvježili njegovu reprezentaciju. I u ovom eksperimentu manipulirali smo snagom distraktora s ciljem provjere jesu li osvježene i neosvježene reprezentacije pod različitim utjecajem distraktora različite snage.

Uradak u kontrolnoj situaciji. Na slici 13 prikazane su distribucije pogrešaka dosjećanja opa-žene u eksperimentu 2b. U situaciji bez distraktora (slika 13 prvi stupac) distribucije dosjećanja osvježenog i neosvježenog podražaja izgledaju usporedivo. Test razlike prosječnih apsolutnih odstupanja to je i potvrdio ($t(9) = 1.68$, $p = 0.13$, $d = 0.5$, $BF_{10} = 0.89$). Ovaj nalaz pokazuje kako osvježavanje pojedine reprezentacije nije dovelo do njenog preciznijeg dosjećanja.

Točnost detekcije u zadatku s distraktorima. U sekvencama na kojima su prikazani distraktori, sudionici su vrlo precizno detektirali ciljni podražaj unutar prikaza s distraktorima ($M \pm se$ za slabe i snažne distraktore): sekvence s dosjećanjem osvježenog podražaja $89.3\% \pm 2.7$ i $89.4\% \pm 3.2$, sekvence s dosjećanjem neosvježenog podražaja $89.8\% \pm 1.6$ i $92\% \pm 2.6$.

Analiza prosječnih apsolutnih odstupanja. Provedba složene (3×2) analize varijance za ponov-ljena mjerenja na faktorima snage distraktora (kontrolna, slabi distraktori, snažni distraktori) i osvježavanja podražaja (osvježeni, neosvježeni) koristeći prosječna apsolutna odstupanja (slika 14) kao zavisnu varijablu pokazala je značajan glavni efekt snage distraktora ($F(2,18) = 17.39$, $p < 0.001$, $\eta_p^2 = 0.66$, $BF_{inc} = 254.5$) i osvježavanja ($F(1,9) = 10.55$, $p = 0.01$, $\eta_p^2 = 0.54$, $BF_{inc} = 3805.2$), te njihovu značajnu interakciju ($F(2,18) = 5.72$, $p = 0.01$, $\eta_p^2 = 0.39$, $BF_{inc} = 3.9$). Naknadne usporedbe pokazale su kako je prosječno apsolutno odstupanje raslo uslijed prikaza slabih ($t(9) = 3.46$, $p = 0.02$, $d = 1.09$, $BF_{10} = 6.21$) i snažnih distraktora ($t(9) = 4.83$, $p = 0.003$, $d = 1.53$, $BF_{10} = 539.15$), te da se dosjećanje uz slabe i snažne distraktore također

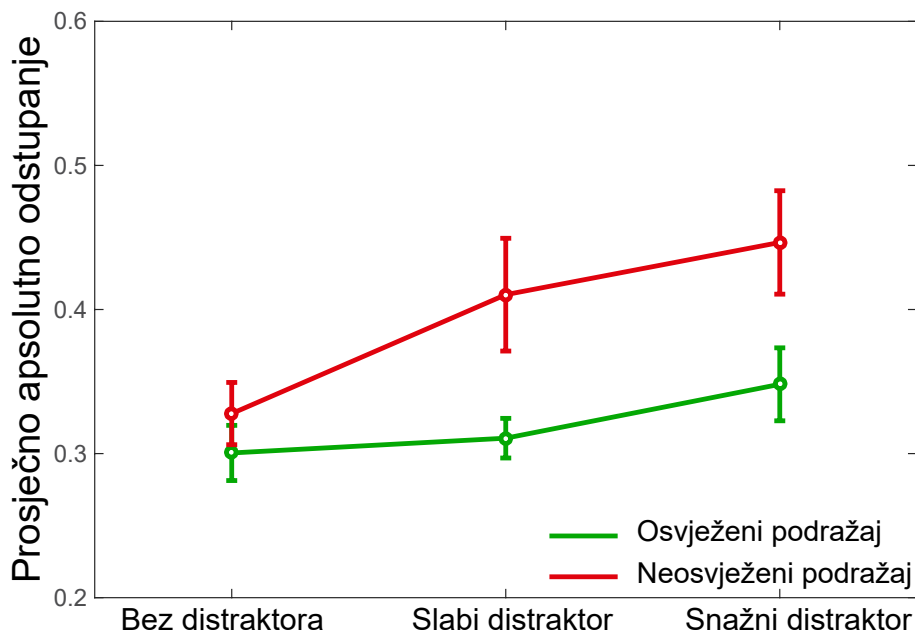


Slika 13. Distribucije pogrešaka dosjećanja u eksperimentu 2b. U različitim redovima prikazane su distribucije dobivene kod dosjećanja osvježenog (gore) i neosvježenog (dolje) podražaja. Pojedini stupci odgovaraju manipulaciji snage distraktora. Vrijednosti prikazane crnim krugovima i pridruženim pogreškama odgovaraju podacima prikupljenima u eksperimentu. Obojene linije prikazuju pristajanje testiranog modela mješovitih distribucija.

razlikovalo ($t(9) = 3.32$, $p = 0.03$, $d = 1.05$, $BF_{10} = 9.17$). Kako bismo kvantificirali interakciju, provedene su dvije odvojene analize varijance koristeći faktor snage distraktora, zasebno za dosjećanje osvježenih i neosvježenih podražaja. Efekt snage distraktora pronađen je kod dosjećanja osvježenih podražaja ($F(2,18) = 5.28$, $p = 0.016$, $\eta_p^2 = 0.37$, $BF_{10} = 3.65$) dok su naknadne usporedbe pokazale značajan porast pogrešaka dosjećanja uslijed snažnih distraktora u odnosu na kontrolnu situaciju ($t(9) = 3.05$, $p = 0.04$, $d = 0.96$, $BF_{10} = 4.78$), ali ne i između kontrolne situacije i slabih distraktora, te slabih i snažnih distraktora (svi $t \leq 2.02$, $p \geq 0.22$, $d \leq 0.64$, $BF_{10} \leq 1.3$). Analiza varijance kod dosjećanja neosvježenih podražaja također je pokazala značajan efekt snage distraktora ($F(2,18) = 16.1$, $p < 0.001$, $\eta_p^2 = 0.64$, $BF_{10} = 186.7$) pri čemu je pogreška dosjećanja u odnosu na kontrolnu situaciju rasla i uslijed slabih ($t(9) = 3.33$, $p = 0.03$, $d = 1.05$, $BF_{10} = 6.8$) i uslijed snažnih ($t(9) = 5.1$, $p = 0.002$, $d = 1.6$, $BF_{10} = 58.65$) distraktora, dok se slabi i snažni distraktori međusobno nisu razlikovali ($t(9) = 2.42$, $p = 0.12$, $d = 0.76$, $BF_{10} = 2.14$).

Sažeto, analizom prosječnih apsolutnih odstupanja pronađen je značajni efekt snage distraktora i to u skladu s postavljenom hipotezom prema kojoj porast snage distraktora dovodi do lošijeg dosjećanja. Također, pronađen je snažniji utjecaj snage distraktora na dosjećanje podražaja koji nisu bili osvježeni u odnosu na podražaje koji su bili osvježeni. Pritom, kod osvježenih podražaja slab interferirajući efekt izazvao je samo snažni distraktor, dok je kod neosvježenih podražaja i slab distraktor doveo do bitnog pada preciznosti dosjećanja. Ovi rezultati većim


dijelom su u skladu s postavljenom hipotezom. Iako nije opažen potpuni efekt snage distraktora prema kojem bi postojale razlike između svih razina ovog faktora ovisno o osvježavanju podražaja u pamćenju, pokazali smo manji efekt distraktora na dosjećanje osvježenih u odnosu na neosvježene podražaje. Ovi nalazi pokazuju kako osvježavanje može djelovati zaštitno na kvalitetu reprezentacija pri čemu je potreban vrlo snažan distraktor da bi narušio kvalitetu reprezentacija; kod neosvježenih reprezentacija i slab distraktor može dovesti do pada uratka.



Slika 14. Prosječna apsolutna odstupanja u eksperimentu 2b ovisno o snazi distraktora i osvježavanju podražaja.

Model mješovitih distribucija. Provjereno je pristajanje hipotetiziranog modela mješovitih distribucija prema kojem se sudionici na svakoj sekvenci mogu točno dosjetiti traženog podražaja, slučajno pogađati, napraviti pogrešku zamjene ili izvijestiti o kvaliteti distraktora. Usporedba s jednostavnijim modelom koji pretpostavlja postojanje jedne normalne i uniformne komponente u ukupnoj distribuciji pogrešaka dosjećanja favorizirala je jednostavniji model u kontrolnoj situaciji ($\Delta AIC = -2.43$, $t(9) = 0.21$, $p = 0.84$) te u situaciji s prisutnim distraktorima ($\Delta AIC = -3.51$, $t(9) = 0.12$, $p = 0.9$). Odvojena usporedba modela u situaciji dosjećanja osvježenih i neosvježenih podražaja pokazala je bolje pristajanje jednostavnijeg modela kod dosjećanja osvježenih podražaja ($\Delta AIC = -30.02$, $t(9) = 3.45$, $p = 0.007$) te kompleksnijeg modela kod dosjećanja neosvježenih podražaja ($\Delta AIC = 25.52$, $t(9) = 1.12$, $p = 0.3$). Važno je napomenuti kako jednostavniji model uspijeva obuhvatiti većinu pogrešaka zamjene i intruzija parametrom slučajnog pogađanja, bez penaliziranja zbog dva dodatna parametra prilikom izračuna AIC vrijednosti. Ova karakteristika jednostavnijeg modela daje mu bitnu prednost pred složenijim modelom. Imajući na umu niske ukupne vrijednosti ΔAIC , te favoriziranje hipotetiziranog modela kod dosjećanja neosvježenih podražaja, ovdje ćemo ipak prikazati složeniji model, ponajprije s

ciljem konzistentnosti obrađenih modela i testiranih parametara u ovom radu. Pritom, važno je napomenuti kako nemogućnost jasnog određivanja favoriziranog modela na temelju podataka zahtjeva ili reviziju modela ili prikupljanje većeg broja sudionika. Kompleksniji model uspješno je reproducirao pogreške dosjećanja opažene u eksperimentu (slika 13) kao i prosječna apsolutna odstupanja ($r^2 = 0.83 \pm 0.074$).



Slika 15. Parametri modela mješovitih distribucija u eksperimentu 2b u funkciji snage distraktora i osvježavanja podražaja. a) vjerojatnost točnih dosjećanja; b) preciznost dosjećanja; c) vjerojatnost pogađanja; d) vjerojatnost pogreške zamjene; e) vjerojatnost intruzija.

Kao i u prethodnim eksperimentima, sljedeći korak sastojao se u testiraju nizova složenih analiza varijance na dobivenim parametrima (slika 15). Analiza parametra vjerojatnosti točnog dosjećanja (slika 15a) pokazala je značajan glavni efekt snage distraktora ($F(2,18) = 10.61$, $p < 0.001$, $\eta_p^2 = 0.51$, $BF_{inc} = 83.9$), osvježavanja ($F(1,9) = 8.14$, $p = 0.019$, $\eta_p^2 = 0.48$, $BF_{inc} = 115.35$), te njihove interakcije ($F(2,18) = 5.95$, $p = 0.01$, $\eta_p^2 = 0.4$, $BF_{inc} = 9.93$). Vjerojatnost točnog dosjećanja osvježenih podražaja nije se mijenjala ovisno o distraktorima ($F(2,18) = 1.45$, $p = 0.26$, $\eta_p^2 = 0.14$, $BF_{10} = 0.54$), dok je dosjećanje neosvježenih podražaja nakon distraktora bilo lošije ($F(2,18) = 18.88$, $p < 0.001$, $\eta_p^2 = 0.68$, $BF_{10} = 399.9$), i to nakon slabih ($t(9) = 4.5$, $p = 0.005$, $d = 1.4$, $BF_{10} = 29.2$) i snažnih distraktora ($t(9) = 5.12$, $p = 0.002$, $d = 1.6$, $BF_{10} = 60.9$); slabi i snažni distraktori se međusobno nisu razlikovali ($t(9) = 0.38$, $p = 1$, $d = 0.1$, $BF_{10} = 0.33$). Analiza preciznosti dosjećanja (slika 15b) pokazala je neznačajan glavni

efekt snage distraktora ($F(2,18) = 0.66$, $p = 0.53$, $\eta_p^2 = 0.07$, $BF_{inc} = 0.2$) uz značajan efekt osvježavanja ($F(1,9) = 11.76$, $p = 0.008$, $\eta_p^2 = 0.57$, $BF_{inc} = 6.1$) na način da su se sudionici preciznije dosjećali osvježenih podražaja. Interakcija ova dva faktora bila je neznačajna ($F(1,9) = 0.7$, $p = 0.42$, $\eta_p^2 = 0.07$, $BF_{inc} = 0.16$).

Slučajna pogađanja (slika 15c) nisu pokazala značajne efekte snage distraktora ($F(2,18) = 0.45$, $p = 0.65$, $\eta_p^2 = 0.05$, $BF_{inc} = 0.16$), osvježavanja ($F(1,9) = 2.96$, $p = 0.12$, $\eta_p^2 = 0.25$, $BF_{inc} = 1.33$) kao niti njihovu interakciju ($F(2,18) = 0.93$, $p = 0.4$, $\eta_p^2 = 0.09$, $BF_{inc} = 0.14$). Pogreške zamjene (slika 15d) pokazale su neznačajan glavni efekt snage distraktora ($F(2,18) = 1.65$, $p = 0.22$, $\eta_p^2 = 0.16$, $BF_{inc} = 0.62$), osvježavanja ($F(1,9) = 2.77$, $p = 0.13$, $\eta_p^2 = 0.24$, $BF_{inc} = 1.61$), ali značajnu interakciju ($F(2,18) = 4.6$, $p = 0.02$, $\eta_p^2 = 0.34$, $BF_{inc} = 1.72$) koja se sastojala u usporedivom dosjećanju između osvježenih i neosvježenih podražaja u kontrolnoj situaciji i situaciji slabih distraktora (svi $t \leq 0.74$, $p \geq 0.48$, $d \leq 0.23$, $BF_{10} \leq 0.39$), te značajno višim pogreškama zamjene prilikom dosjećanja neosvježenih podražaja (u odnosu na osvježene) nakon snažnog distraktora ($t(9) = 2.82$, $p = 0.02$, $d = 0.89$, $BF_{10} = 3.55$) iako uz tek umjerenu snagu dokaza.

Naposljetku, proporcije pogrešaka intruzije (slika 15e) razlikovale su se od 0 prilikom dosjećanja neosvježenih podražaja, kod slabih i snažnih distraktora, te kod dosjećanja osvježenih podražaja uslijed snažnih distraktora (svi $t \geq 2.55$, $p \leq 0.03$, $d \geq 0.81$, $BF_{10} \geq 2.56$), ali ne i kod dosjećanja osvježenih podražaja kada je prikazan slabi distraktor ($t(9) = 1.35$, $p = 0.21$, $d = 0.43$, $BF_{10} = 0.6$). Iako je primamljiva interpretacija ovog rezultata kako su osvježeni podražaji zaštićeni od intruzija kod prikaza slabih distraktora, važno je istaknuti kako je snaga dokaza u prilog takvoj hipotezi tek anegdotalna. Analiza varijance na ovom parametru nije pokazala glavni efekt snage distraktora ($F(1,9) = 0.7$, $p = 0.42$, $\eta_p^2 = 0.07$, $BF_{inc} = 0.5$), osvježavanja ($F(1,9) = 3.52$, $p = 0.09$, $\eta_p^2 = 0.28$, $BF_{inc} = 0.91$), kao ni značajnu interakciju ($F(1,9) = 2.87$, $p = 0.13$, $\eta_p^2 = 0.24$, $BF_{inc} = 0.99$).

U eksperimentu 2b, hipotetizirani probabilistički model dosjećanja nije potvrđen. Konkretno, parsimoničniji model koji pretpostavlja kako dosjećanje možemo opisati točnim dosjećanjima i slučajnim pogađanjima pokazao je marginalnu prednost usporedbom AIC vrijednosti. Ranije je spomenuto kako takav jednostavniji model uspijeva opisati dio pogrešaka zamjene i intruzija komponentom slučajnog pogađanja, a da pritom procjena pristajanja tog modela, za razliku od hipotetiziranog kompleksnijeg modela, nije penalizirana zbog dva dodatna parametra. Ukratko, od pet parametara analiziranog modela, samo je proporcija točnih dosjećanja pokazala značajno variranje s promjenom u snazi distraktora, i to samo onda kada su se sudionici dosjećali podražaja koji prethodno nije bio osvježen. Kod tih dosjećanja, i slabi i snažni distraktori jednako su smanjili vjerojatnost točnog dosjećanja. Ovaj nalaz ističe dvije karakteristike utjecaja distraktora na osvježene i neosvježene podražaje: a) osvježeni podražaji ostaju relativno

zaštićeni od distraktora, slično prioritiziranim podražajima iz eksperimenta 2a; b) neosvježeni podražaji osjetljivi su na distraktore, pri čemu su dovoljni i slabi distraktori da bi značajno degradirali kvalitetu reprezentacija (nema razlike između slabih i snažnih distraktora). Opaženi pad u vjerojatnosti točnih dosjećanja nije se konzistentno odrazio na porast vjerojatnosti neke od pogrešaka. Konkretno, nije pronađena jednaka interakcija na parametru koji opisuje neku od tri pogreške. Čini se kako su sudionici, kada su griješili u ovom eksperimentu nakon prikaza distraktora, manje konzistentno radili određenu vrstu pogrešaka.


5.4 Eksperiment 3

U posljednjem eksperimentu željeli smo provjeriti kakva je uloga snage distraktora u različitim fazama obrade u VRP, konkretno, kodiranju, zadržavanju i dosjećanju. U zadatku VRP-a s pamćenjem boja prikazivali smo distraktore različite snage u različitim fazama obrade podražaja. Distraktori su mogli biti prikazani neposredno nakon prikaza za pamćenje (kodiranje), između kodiranja, ali prije dosjećanja (zadržavanje), te nakon što je jedan od podražaja označen kao podražaj čiju boju sudionici trebaju prizvati (dosjećanje).

Uradak u kontrolnoj situaciji. Distribucije pogrešaka dosjećanja u eksperimentu 3 prikazane su na slici 16, a uradak u kontrolnoj prikazan je u prvom stupcu. Provedbom jednostavne analize varijance za ponovljena mjerenja na prosječnim apsolutnim odstupanjima dobivenima u različitim fazama obrade kada distraktor nije bio prikazan, pronađena je neznačajna razlika ($F(2,22) = 1.15$, $p = 0.34$, $\eta_p^2 = 0.09$, $BF_{10} = 0.39$). Ovaj nalaz pokazuje kako prikazivanje maskirajućeg podražaja u različitim fazama obrade nije različito djelovalo na uradak. Ovaj rezultat je vrlo važan jer pokazuje kako su podražaji u svim situacijama bili usporedivo kodirani. Specifično, prikaz maske u ranoj fazi nije doveo do lošijeg kodiranja podražaja. Kada bi to bio slučaj, razlike između kontrolne situacije i situacija s distraktorima morali bismo tumačiti imajući na umu početnu razliku u snazi reprezentacija, a ne samo faze u kojoj su prikazani distraktori. Sve razlike između skupina uslijed prikazivanja distraktora možemo pripisati isključivo distraktoru i njegovom trajanju.


Točnost detekcije u zadatku s distraktorima. U sekvencama u kojima je sudionicima prikazan distraktor, točnost detekcije bila je iznad razine slučaja, i to u svim situacijama ($M \pm se$ za slabi i snažni distraktor): u fazi kodiranja $83.3\% \pm 2.98$ i $86.7\% \pm 1.7$; u fazi zadržavanja $91.9\% \pm 1.4$ i $96\% \pm 1.56$; u fazi dosjećanja $90.6\% \pm 1.6$ i $94.8\% \pm 1.25$.

Analiza prosječnih apsolutnih odstupanja. Provedbom složene analize varijance (3×3) na faktorima faza obrade (kodiranje, zadržavanje, dosjećanje) i snaga distraktora (bez distraktora, slabi distraktor, snažni distraktor) na prosječnim apsolutnim odstupanjima (slika 17) pronađen



Slika 16. Distribucije pogrešaka dosjećanja u eksperimentu 3. U različitim redovima prikazane su distribucije dosjećanja kod prikaza distraktora u različitim fazama obrade. Pojedini stupci odgovaraju manipulaciji snage distraktora. Vrijednosti prikazane crnim krugovima i pridruženim pogreškama odgovaraju podacima prikupljenima u eksperimentu. Obojene linije prikazuju pristajanje testiranog modela mješovitih distribucija.

je značajni glavni efekt snage distraktora ($F(2,22) = 20.33$, $p < 0.001$, $\eta_p^2 = 0.65$, $BF_{inc} = 4.666e+12$), faze obrade ($F(2,22) = 70.08$, $p < 0.001$, $\eta_p^2 = 0.86$, $BF_{inc} = \infty$), te njihova interakcija ($F(4,44) = 29.8$, $p < 0.001$, $\eta_p^2 = 0.73$, $BF_{inc} = 7.899e+10$). Naknadne analize pokazale su kako je prosječno apsolutno odstupanje raslo uslijed slabog ($t(11) = 4.98$, $p < 0.001$, $d = 1.43$, $BF_{10} = 12.8$) te snažnog distraktora ($t(11) = 5.83$, $p < 0.001$, $d = 1.68$, $BF_{10} = 17.6$) u usporedbi s kontrolnom situacijom. Dosjećanje uslijed distraktora različite snage nije se međusobno razlikovalo ($t(11) = 0.12$, $p = 1$, $d = 0.04$, $BF_{10} = 0.18$). Ove razlike proizlaze u potpunosti iz različitog uratka uslijed distraktora u fazi obrade. Usporedba kontrolne i situacije sa slabim ($t(11) = 7.07$, $p < 0.001$, $d = 2.04$, $BF_{10} = 1139.4$) i snažnim distraktorom ($t(11) = 8.3$, $p < 0.001$, $d = 2.41$, $BF_{10} = 4483.6$) pokazala je kako je dosjećanje bilo lošije nakon prikazivanja distraktora. Slabi i snažni distraktor se međusobno nisu razlikovali ($t(11) = 0.41$, $p = 0.69$, $d = 0.12$, $BF_{10} = 0.3$). U fazi zadržavanja (svi $t \leq 0.97$, $p \geq 0.36$, $d \leq 0.28$, $BF_{10} \leq 0.43$) te fazi dosjećanja (svi $t \leq 0.83$, $p \geq 0.42$, $d \leq 0.24$, $BF_{10} \leq 0.39$) nije bilo razlike između kontrolne situacije i situacije s distraktorima, te situacija s različitom snagom distraktora.




Slika 17. Prosječna apsolutna odstupanja u eksperimentu 3 ovisno o snazi distraktora i fazi prikaza distraktora.

Analizom rezultata trećeg eksperimenta nije dobivena potvrda hipoteza o ulozi snage distraktora. Konkretno, nismo pronašli očekivanu razliku između slabih i snažnih distraktora. Nadalje, pronašli smo kako distraktirajući podražaji dovode do lošijeg dosjećanja, ali samo kada su prikazani u ranim fazama obrade, točnije fazi kodiranja. Ovi nalazi u skladu su s hipotezom koja pretpostavlja kako su podražaji u VRP-u relativno zaštićeni od distraktora jednom nakon što je kodiranje i konsolidacija podražaja u potpunosti dovršena, uz pretpostavku kako različita mozgovna područja obavljaju kodiranje i pohranu podražaja (Bettencourt i Xu, 2016; Xu, 2017). Važno, u ovom eksperimentu nije pronađena uloga snage distraktora. Kada su prikazani neposredno nakon podražaja za pamćenje, slabi i snažni distraktori doveli su do jednake promjene u dosjećanju. Kada su pak prikazani u fazi zadržavanja i dosjećanja, slabi i snažni distraktori nisu se razlikovali od kontrolne situacije.

Model mješovitih distribucija. Provjereno je pristajanje modela mješovitih distribucije prema kojem dosjećanje u zadatku može biti posljedica točnih dosjećanja, pogađanja (uslijed zaboravljanja), pogrešaka zamjene i intruzija. U usporedbi s pojednostavljenim modelom koji pretpostavlja kako su dosjećanja posljedica točnih dosjećanja i pogađanja, kompletni model pokazao je bolje pristajanje podacima u situacijama s distraktorima ($\Delta AIC = 69.57$, $t(11) = 1.07$, $p = 0.31$), dok je jednostavniji model pokazao bolje pristajanje u kontrolnoj situaciji od pojednostavljene verzije predloženog modela bez parametra intruzija ($\Delta AIC = -20.5$, $t(11) = 1.58$, $p = 0.14$) iako s većim varijabilitetom među sudionicima. Kompleksniji model uspješno je reproducirao distribucije pogrešaka dosjećanja (obojene linije na slici 16) te prosječna apsolutna odstupanja (r^2

= 0.98 ± 0.004).

Sljedeći korak bila je provedba serije složenih analiza varijance (3 x 3) na parametrima dobivenima modelom (slika 18). Kada je kao zavisna varijabla korištena vjerojatnost točnog dosjećanja (slika 18a), analiza varijance pokazala je značajan glavni efekt snage distraktora ($F(2,22) = 11.98$, $p < 0.001$, $\eta_p^2 = 0.52$, $BF_{inc} = 3.278e+11$), faze obrade ($F(2,22) = 67.91$, $p < 0.001$, $\eta_p^2 = 0.86$, $BF_{inc} = 6.005e+15$) te njihovu interakciju ($F(4,44) = 34.1$, $p < 0.001$, $\eta_p^2 = 0.76$, $BF_{inc} = 4.208e+10$). Kao i u slučaju prosječnog apsolutnog odstupanja ovi efekti su proizlazili iz značajne razlike kontrolne situacije i slabih ($t(11) = 7.08$, $p < 0.001$, $d = 2.04$, $BF_{10} = 1148.5$) te snažnih ($t(11) = 7.6$, $p < 0.001$, $d = 2.2$, $BF_{10} = 2057.8$) distraktora. Slabi i snažni distraktori nisu se međusobno razlikovali u utjecaju na promjene u vjerojatnosti dosjećanja ($t(11) = 0.26$, $p = 0.8$, $d = 0.08$, $BF_{10} = 0.3$). U fazi zadržavanja (svi $t \leq 0.79$, $p \geq 0.45$, $d \leq 0.23$, $BF_{10} \leq 0.37$) i fazi dosjećanja (svi $t \leq 1.6$, $p \geq 0.14$, $d \leq 0.46$, $BF_{10} \leq 0.79$) te razlike nisu bile značajne.



Slika 18. Parametri modela mješovitih distribucija u eksperimentu 3 u funkciji snage distraktora i faze prikaza distraktora. a) vjerojatnost točnih dosjećanja; b) preciznost dosjećanja; c) vjerojatnost pogađanja; d) vjerojatnost pogreške zamjene; e) vjerojatnost intruzija.

Analiza parametra preciznosti dosjećanja (slika 18b) pokazala je značajan glavni efekt snage distraktora, iako uz nisku snagu dokaza ($F(2,22) = 4.64$, $p = 0.02$, $\eta_p^2 = 0.3$, $BF_{inc} = 1.87$), te neznačajan glavni efekt faze ($F(2,22) = 1.36$, $p = 0.28$, $\eta_p^2 = 0.11$, $BF_{inc} = 0.19$) i

njihovu interakciju ($F(4,44) = 0.62$, $p = 0.65$, $\eta_p^2 = 0.05$, $BF_{inc} = 0.09$). Značajan efekt snage distraktora proizlazio je iz razlike kontrolne situacije i najsnažnijeg distraktora ($t(11) = 3.71$, $p = 0.01$, $d = 1.07$, $BF_{10} = 4.77$). Dodatni testovi pokazali su kako su se kontrolna i situacija najsnažnijeg distraktora granično razlikovale samo u fazi kodiranja ($t(11) = 2.15$, $p = 0.06$, $d = 0.62$, $BF_{10} = 1.6$). Parametar slučajnih pogađanja (slika 18c) varirao je u funkciji faze obrade ($F(2,22) = 11.82$, $p < 0.001$, $\eta_p^2 = 0.52$, $BF_{inc} = 52.82$), ali ne i u funkciji snage distraktora ($F(2,22) = 0.09$, $p = 0.91$, $\eta_p^2 = 0.01$, $BF_{inc} = 0.17$), dok je njihova interakcija bila značajna, ali uz, iako niski, snažniji nalaz u prilog nul nego alternativnoj hipotezi ($F(4,44) = 2.9$, $p = 0.03$, $\eta_p^2 = 0.21$, $BF_{inc} = 0.6$). Interakcija se sastojala u značajno višem pogađanju u fazi kodiranja nego u preostalim fazama i to uslijed slabih (svi $t \geq 2.14$, $p \leq 0.06$, $d \geq 0.62$, $BF_{10} = 1.5$) i snažnih distraktora (svi $t \geq 2.13$, $p \leq 0.06$, $d \leq 0.62$, $BF_{10} = 3.5$), iako je snaga dokaza za tu razliku bila nepostojeća do anegdotalna. Međutim, unutar faze kodiranja, pogađanje uslijed distraktora se nije razlikovalo od kontrolne situacije (svi $t \leq 1.83$, $p \geq 0.1$, $d \leq 0.53$, $BF_{10} \leq 1.03$).

Pad u vjerojatnosti točnih dosjećanja odrazio se u pogreškama zamjene i intruzijama. Analiza varijance provedena na pogreškama zamjene (slika 18d) pokazala je značajan glavni efekt snage distraktora ($F(2,22) = 9.95$, $p < 0.001$, $\eta_p^2 = 0.48$, $BF_{inc} = 1623.5$), faze obrade ($F(2,22) = 18.97$, $p < 0.001$, $\eta_p^2 = 0.63$, $BF_{inc} = 1.267e+7$) te njihovu interakciju ($F(2,22) = 6.02$, $p < 0.001$, $\eta_p^2 = 0.35$, $BF_{inc} = 319.9$). Obrazac interakcije pratio je promjene već opažene kod vjerojatnosti točnog dosjećanja i u potpunosti se mogao objasniti razlikama u fazi kodiranja između kontrolne i situacije slabih ($t(11) = 3.49$, $p = 0.005$, $d = 1$, $BF_{10} = 10.26$) te snažnih distraktora ($t(11) = 3.7$, $p = 0.003$, $d = 1.1$, $BF_{10} = 14.81$). U fazi kodiranja, slabi i snažni distraktori doveli su do usporedivih promjena u vjerojatnosti pogrešaka zamjena ($t(11) = 0.09$, $p = 0.9$, $d = 0.03$, $BF_{10} = 0.29$). Konačno, nije pronađena niti jedna značajna razlika u fazi zadržavanja (svi $t \leq 1.69$, $p \geq 0.12$, $d \leq 0.49$, $BF_{10} \leq 0.87$) niti u fazi dosjećanja (svi $t \leq 0.35$, $p \geq 0.73$, $d \leq 0.1$, $BF_{10} \leq 0.3$).

Prije testiranja razlika na parametru intruzija (slika 18e), provjerili smo razlikuju li se prosječne vrijednosti ovog parametra u svim situacijama od 0. Provedba t testova za jedan uzorak pokazala je kako se ovaj parametar u fazi dosjećanja ne razlikuju od 0 niti u situaciji slabog niti u situaciji snažnog distraktora (svi $t \leq 1.5$, $p \geq 0.17$, $d \leq 0.43$, $BF_{10} \leq 0.7$) dok su ostali testovi pokazali kako se prosječne proporcije razlikuju od 0, uz samo jednu graničnu vrijednost (svi $t \geq 1.8$, $p \leq 0.09$, $d \geq 0.53$, $BF_{10} \geq 1$). Analiza varijance na parametru intruzija pokazala je značajan glavni efekt faze ($F(2,22) = 29.28$, $p < 0.001$, $\eta_p^2 = 0.73$, $BF_{inc} = 9.715e+6$), te neznačajan glavni efekt snage distraktora ($F(1,11) = 0.12$, $p = 0.74$, $\eta_p^2 = 0.01$, $BF_{inc} = 0.2$) i njihovu interakciju ($F(2,22) = 0.05$, $p = 0.95$, $\eta_p^2 = 0.004$, $BF_{inc} = 0.16$). Značaj efekt faze obrade proizlazio je iz viših vjerojatnosti intruzija u odnosu na fazu zadržavanja ($t(11) = 4.7$, p

= 0.002, $d = 1.36$, $BF_{10} = 184.6$) i fazu dosjećanja ($t(11) = 6.5$, $p < 0.001$, $d = 1.88$, $BF_{10} = 3092.87$). Razlika u vjerojatnosti intruzija u fazi zadržavanja i fazi dosjećanja bila je granično neznačajna, iako je Bayesov faktor sugerirao višu vjerojatnost intruzija u fazi zadržavanja ($t(11) = 2.63$, $p = 0.07$, $d = 0.76$, $BF_{10} = 10.8$).

Pretpostavljeni model mješovitih distribucija u posljednjem eksperimentu pokazao je bolje pristajanje podacima u situacijama kada su prikazani distraktori. Taj nalaz pokazuje kako pogreškama zamjene i intruzijama možemo opisati bitan dio pogrešaka koje nastaju uslijed prikaza distraktora. Analiza parametara modela mješovitih distribucija pratila je razlike opažene kod analize prosječnih apsolutnih odstupanja. Vjerojatnost točnih dosjećanja pala je u fazi kodiranja uslijed prikaza distraktora, dok su vjerojatnosti pogrešaka zamjena i intruzija u istoj fazi porasle. Pritom, slabi i snažni distraktori doveli su do istih efekata, odnosno, niti kod jednog parametra nije pronađena sustavna razlika između ove dvije razine nezavisne varijable. Promjena u vjerojatnostima pogrešaka zamjena pokazuje kako prikaz distraktora u fazi kodiranja unosi šum u reprezentaciju prostornog razmještaja podražaja. Kao posljedica toga, sudionici prilikom dosjećanja u većoj mjeri navode boju nekog od podražaja koji je prikazan (zapamćen) ali nije tražen za dosjećanje. Promjene u intruzijama pokazuju kako novo senzorno podraživanje, u periodu dok konsolidacija nije dovršena, može lako zamijeniti podražaje u VRP. Vjerojatnost pogađanja pokazala je trend ka porastu u fazi kodiranja iako su dokazi u prilog tome bili mali i nejednoznačni. Slične nalaze pronašli smo analizom preciznosti dosjećanja.

6 Opća rasprava

Svakodnevna interakcija s okolinom podrazumijeva kontinuirano integriranje dostupnih vidnih informacija i obradu dinamične okoline. Velik broj istraživanja sugerira kako je VRP proces koji omogućava takvu adaptivnu integraciju vidnih informacija (Irwin, 1996). Sadržaj VRP-a objedinjuje se s dostupnim osjetnim informacijama i oblikuje percepciju (Aagten-Murphy i Bays, 2018; Oostwoud Wijdenes, Marshall i Bays, 2015; Stewart i Schütz, 2018), te često dovodi do procesiranja osjeta kao sustavno sličnijima sadržaju VRP-a (Mendoza, Schneiderman, Kaul i Martinez-Trujillo, 2011; Scocchia, Cicchini i Triesch, 2013). Osim toga, sadržaj VRP-a mehanizmom *odozgo-prema-dolje* upravlja selektivnom pažnjom (Downing, 2000). Iako ovi procesi tipično olakšavaju uradak u trenutnom zadatku (Kiyonaga, Scimeca, Bliss i Whitney, 2017), istraživanja pokazuju kako su oni tipično automatski, što znači da će se odvijati čak i kada ne potpomažu obavljanje zadataka (Soto, Hodsoll, Rotshtein i Humphreys, 2008). Istraživanja su pokazala da je, osim na bihevioralnoj razini, utjecaj sadržaja radnog pamćenja vidljiv i na neuralnoj razini (Cattaneo, Pisoni, Papagno i Silvanto, 2011; Sneve, Sreenivasan, Alnæs, Endestad i Magnussen, 2015).

Važno je napomenuti kako odnos sadržaja VRP-a i senzornog iskustva nije jednosmjernan. Sadržaj VRP-a, premda ključan za trenutni zadatak, pod utjecajem je informacija iz okoline neovisno o njihovoj važnosti za isti zadatak. Ovakav recipročan i interakcijski odnos omogućava fleksibilno upravljanje i mijenjanje potrebnih informacija, i u skladu je s tipično nepredvidivom okolinom. Pritom, nadolazeće osjetne informacije, neovisno o važnosti, natječu se za iste resurse kao i sadržaji koje želimo pohraniti u VRP (Herwig i sur., 2010; Macoveanu i sur., 2007). Pa ipak, ljudi većinu radnih zadataka uspijevaju obaviti gotovo optimalno. U tome nam ponajprije pomažu procesi (selektivne) pažnje koji facilitiraju obradu podražaja na koje je pažnja usmjerena, poboljšavajući osjetljivost na odabrane podražaje (Bashinski i Bacharach, 1980; Carrasco, Penpeci-Talgar i Eckstein, 2000) te ubrzavajući njihovu obradu (Posner, 1980). Isti procesi pomažu inhibirati podražaje na koje selektivna pažnja nije usmjerena (Bahcall i Kowler, 1999; Mathôt, Hickey i Theeuwes, 2010; Mounts, 2000; za pregled vidi Reynolds i Chelazzi, 2004). Iako VRP raspolaze mehanizmima koji mogu pomoći u obrani relevantnih sadržaja od irelevantnih informacija iz okoline, upamćeni podražaji gotovo nikada nisu u potpunosti zaštićeni.

U ovom radu fokus je bio usmjeren na ispitivanje posljedica prisutnosti irelevantnih perceptivnih distraktora na obavljanje zadataka VRP-a. Ovo pitanje daleko je od neistraženog i rezultati pokazuju kako je sadržaj VRP-a osjetljiv na prikaz distraktora (vidi npr. Bennett i Cortese, 1996; Broadbent i Broadbent, 1981; Brockmole i sur., 2002; Fallon i sur., 2018; Jha i sur., 2004; Jiang i Kumar, 2004; Magnussen i Greenlee, 1992; Makovski i sur., 2008; Rademaker i

sur., 2015). Ipak, istraživanja do sada nisu sustavno ispitivala važnost snage reprezentacija u VRP-u i snage distraktora, dva faktora o kojima primarno ovisi kakve će posljedice distraktori imati na uradak u zadatku VRP-a. Kako bismo to provjerili provedena su tri eksperimenta u kojima je manipulirano snagom reprezentacija kao i snagom distraktora. Na temelju prethodnih istraživanja, kvaliteta reprezentacija u VRP-u, tj. njihova snaga, manipulirana je variranjem broja podražaja koji se pamti te vremenom dostupnim za njihovo kodiranje (eksperiment 1), davanjem prioriteta pojedinom podražaju za dosjećanje (eksperiment 2a), osvježavanjem pojedinog podražaja (eksperiment 2b), te prikazom distraktora u pojedinoj fazi obrade (eksperiment 3). Snaga distraktora je u svim eksperimentima manipulirana kroz trajanje senzornog podraživanja, uz pretpostavku da duže senzorno podraživanje rezultira dužim angažmanom senzornih područja koja obrađuju distraktore. Prilikom ispitivanja utjecaja distraktora, osim na opće pogreške dosjećanja, poseban naglasak stavljen je i na izvore tih pogrešaka. Ovakav sveobuhvatan pristup bio je potreban jer neka od prethodnih istraživanja pokazala su kako se ukupna pogreška dosjećanja uslijed prikaza distraktora ne mijenja, ali se zato mijenjaju različiti izvori pogrešaka (Fallon i sur., 2018).

Ukratko, u provedenom istraživanju pokazano je kako snaga reprezentacije podražaja u VRP-u određuje otpornost podražaja na distraktore, no, kao i što je očekivano, snaga reprezentacije nije se pokazala jedinstvenim konceptom. Veća količina resursa pridanih podražaju, davanje prioriteta podražaju za dosjećanje (*odozgo-prema-dolje* procesi), osvježavanje podražaja prije dosjećanja (*odozdo-prema-gore* procesi), te formiranje stabilne reprezentacije - tek su četiri načina na koje je moguće utjecati na snagu reprezentacije u VRP-u. Glavni fokus ovog istraživanja bio je ipak na ulozi snage distraktora. Kroz provedene eksperimente demonstrirali smo a) kontinuirane promjene u pogrešci dosjećanja s porastom snage distraktora, i b) *sve-ili-ništa* djelovanje distraktora. U eksperimentima 1 i 2b, pronađen je pretpostavljeni efekt snage distraktora prema kojem su snažniji distraktori doveli do veće pogreške od slabijih distraktora. Naknadni testovi pokazali su kako se ovaj efekt razlikuje ovisno o snazi reprezentacija. U eksperimentima 2a i 3 pronađen je *sve-ili-ništa* efekt distraktora, prema kojem distraktori utječu na dosjećanje neovisno o snazi ili ne utječu uopće, ponovno neovisno o snazi. Pokušaj da obuhvatimo specifične pogreške dosjećanja pokazao je kako su pogreške zamjene i intruzije sastavni dijelovi dosjećanja u prisustvu distraktora.

U prvom eksperimentu snaga reprezentacija u VRP-u varirana je brojem podražaja koji se pamti i dostupnim vremenom kodiranja. Prethodna istraživanja pokazala su kako je pad uratka kod dosjećanja uslijed povećavanja broja podražaja koji se pamti jedna od glavnih karakteristika VRP-a (npr. Bays, 2014; Bays i sur., 2009; Gorgoraptis i sur., 2011; Luck i Vogel, 1997; Mazyar i sur., 2012, 2013; van den Berg i sur., 2012; Wilken i Ma, 2004). Osim toga, kvaliteta reprezentacije ovisi i o dostupnom vremenu kodiranja i to tako da se s produžetkom vremena

kodiranja formiraju snažnije reprezentacije (npr. Bays i sur., 2011; Smyth, Hay, Hitch i Horton, 2005; Vogel i sur., 2006). U provedenom eksperimentu korištenjem tri duljine niza za pamćenje i tri vremena kodiranja gotovo je u potpunosti ostvarena željena modulacija snage reprezentacija - reprezentacije su se za svaku razinu broja podražaja koji se pamtio razlikovale između najkraćeg i najdužeg vremena kodiranja, dok je srednje vrijeme kodiranja bilo usporedivo s najkraćim odnosno najdužim, ovisno o broju podražaja koji se pamtio. Iako je odabir broja podražaja i vremena kodiranja bio utemeljen na prethodno navedenim istraživanjima, važno je napomenuti kako su istraživanja na kojima smo temeljili odluke dominantno koristila orijentacije kao podražajni materijal. Istraživanja pak pokazuju kako se potrebno vrijeme kodiranja može razlikovati čak između jednostavnih vidnih karakteristika kao što su boje i orijentacije (Becker, Miller i Liu, 2013; Hao, Becker, Ye, Liu i Liu, 2018; Rideaux i Edwards, 2016).

Neovisno o činjenici kako nismo ostvarili potpunu modulaciju snage reprezentacija, dobiveni rezultati omogućili su provjeru hipoteze o utjecaju snage distraktora. Kada je snaga distraktora testirana neovisno o faktorima kojima je manipulirana snaga reprezentacija u VRP-u, pronađen je očekivani efekt prema kojem je svaki porast u snazi distraktora doveo do lošijeg dosjećanja. Ovaj efekt nije u potpunosti izdržao daljnje testove: kod najmanjeg broja podražaja, slabi i snažni distraktor jednako su narušili kvalitetu reprezentacija, dok je kod pamćenja najvećeg broja podražaja samo najsnažniji distraktor doveo do pada u uratku; samo je kod pamćenja niza srednje duljine, pronađen očekivani efekt. Primamljivo je pretpostaviti kako ovi rezultati pružaju dokaze u prilog mehanizmima (voljne) selektivne pažnje ili uskog grla (Pashler, 1994). Prema prvom mehanizmu, sudionici bi potencijalno mogli uključivati procese pažnje u situacijama niske kvalitete reprezentacija u VRP-u pri čemu bi se samo snažni distraktori "probili" kroz takav filter. Prema mehanizmu uskog grla, pamćenjem šest podražaja dosegnut je kapacitet za paralelno procesiranje, pri čemu se samo snažni distraktori uspijevaju "probiti" kroz usko grlo; kod pamćenja dva podražaja distraktori su obrađeni neovisno o snazi zbog čega i slabi i snažni distraktori ostvaruju jednak utjecaj. Ipak, točnosti detekcije ciljnog podražaja (u prikazu distraktora) kod pamćenja dva i šest podražaja su usporedive s preostalima opaženima u ovom istraživanju, zbog čega je teško tvrditi kako npr. slabi distraktori nisu bili obrađeni kod pamćenja najdužeg niza. Konačno, ključan nalaz protiv ovakve interpretacije jest onaj o anegdotalnim razinama dokaza o nepostojanju razlika kod usporedbe utjecaja snage distraktora prilikom pamćenja najkraćeg i najdužeg niza.

Važna pretpostavka vezana uz prvi eksperiment bila je ona u veličini promjene uslijed distraktora ovisnoj o kvaliteti početne reprezentacije. S tim ciljem, u prvom eksperimentu stvoreno je devet situacija različite kvalitete reprezentacija. Pretpostavili smo kako će distraktori najmanje utjecati na dosjećanje kada će kvaliteta reprezentacija biti visoka, te da će taj utjecaj rasti kako će kvaliteta reprezentacija padati (s porastom broja podražaja koji se pamti). Analize su

pokazale kako je promjena uslijed distraktora uistinu najmanja kod pamćenja najmanjeg broja podražaja, dok je bila usporediva kod pamćenja dva dulja niza podražaja. Pritom, promjene su uslijed prikaza distraktora bile iste za sva vremena kodiranja unutar pojedinog broja podražaja koji se pamtio. Drugim riječima, dok su očekivanja uglavnom potvrđena kada se u obzir uzme snaga reprezentacija manipulirana brojem podražaja koji se pamtio, manipulacije vremenom kodiranja nisu pokazale dovoljnu osjetljivost unutar pojedine duljine niza.

Uzevši u obzir dobivene rezultate, kakav je zaključak o odnosu snage distraktora i snage reprezentacija u VRP-u na temelju eksperimenta 1? Pretpostavka je bila kako se uradak kontinuirano mijenja sa snagom distraktora, a brzina te promjene raste kako pada kvaliteta reprezentacije. Naši rezultati djelomično potvrđuju ovu pretpostavku i pokazuju kako uradak kontinuirano pada s porastom snage distraktora, te da su te promjene manje kada je snaga reprezentacije visoka; međutim potpuni efekt distraktora (pogreške dosjećanja: bez distraktora < slabi distraktor < snažni distraktor) nije potvrđen na svakoj razini snage reprezentacija. Allen, Baddeley i Hitch (2017) kroz sedam eksperimenata pokazali su pad uratka kod pamćenja boja, oblika te objekata (boje i oblici) kao posljedicu prikaza distraktora paralelno s podražajima koje su sudionici trebali pamtit. Posebno zanimljiv nalaz dobiven je u eksperimentu u kojem su autori varirali brojem distraktora koji se prikazivao uz podražaje za pamćenje. Pronađen je lošiji uradak kod prikaza jednog distraktora u odnosu na kontrolnu situaciju bez distraktora; uradak s jednim distraktorom bio je bolji od pamćenja uz četiri distraktora, dok daljnje povećanje broja distraktora nije dodatno narušavalo dosjećanje. Ovo istraživanje daje naslutiti kako snaga distraktora ne dovodi do kontinuiranog pada uratka, slično kao što niti povećanje broja podražaja koji se pamti nakon određenog broja podražaja neće dovesti do daljnjeg (značajnog) porasta pogreške dosjećanja. Jedan način kojim bismo mogli detaljnije provjeriti točan odnos snage reprezentacija (manipulirane brojem podražaja kao u našem eksperimentu 1) i snage distraktora sastojao bi se u korištenju manjih pomaka i većeg raspona broja podražaja za pamćenje (npr. 1, 2, 3, 4, 6, 8) te snage distraktora (npr. pomaci po 50ms od 0ms do 500ms). Preciznost dosjećanja u takvom istraživanju mogla bi se modelirati većim brojem konkretnih funkcija (npr. eksponencijalno ili potencijsko osipanje, linearni ili bilinearan pad) s ciljem provjere koja funkcija najbolje opisuje odnos snage distraktora i preciznosti dosjećanja.

Osim uloge snage distraktora, u eksperimentu 1 ispitivana je uloga snage reprezentacija manipulirana brojem podražaja koji se pamti i dostupnim vremenom kodiranja. Iako nam nije poznat teorijski okvir koji predviđa utjecaj distraktora ovisno o ovako definiranoj snazi reprezentacije podražaja, nekoliko autora predložilo je kako obrada perceptivnih distraktora ovisi o broju podražaja u VRP-u, a na taj način smo i mi manipulirali snagu reprezentacija. Posebno utjecajna je teorija kognitivnog opterećenja (Konstantinou i sur., 2014; Lavie, 2005; Lavie i Tsal, 1994) koja pretpostavlja kako se distraktirajući materijal obrađuje samo kada je kognitivno

opterećenje (broj podražaja koji se pamti) VRP-a malo te ostavlja dio resursa neiskorištenima i dostupnima za obradu distraktora. Ova teorija nekompatibilna je iz nekoliko razloga s pristupom od kojeg polazi naš rad. Iako objašnjava utjecaj distraktora u terminima resursa, teorija kognitivnog opterećenja kompatibilnija je sa starijim modelima utora prema kojima određeni dio kapaciteta VRP-a može ostati neiskorišten, npr. u situaciji kada je broj podražaja koji se pamti manji od broja dostupnih utora. Nadalje, iako je teorija orijentirana na utjecaj opterećenja VRP-a na obradu distraktora, implicira da uz veće opterećenje VRP-a distraktori ne mogu utjecati jer nisu niti obrađeni. Kao što je ranije navedeno, veći efekt distraktora uz manji broj podražaja koji se pamti može biti posljedica veće promjene u količini resursa koju svaki podražaj ima nakon ponovne raspodjele uslijed kodiranja distraktora. Pod malo vjerojatnim uvjetom o jednakoj raspodijeli resursa na podražaje koji se pamte i distraktore, prilikom kodiranja dva podražaja svaki podražaj dobije 50% resursa, dok uvođenjem dva distraktora svaki od kodiranih podražaja završi s četvrtinom resursa; isti scenarij uz pamćenje šest podražaja rezultirao bi promjenom s otprilike 17% na 13% resursa po podražaju. Konačno, hipoteze postavljene u ovom radu, kao i dobiveni nalazi, govore o suprotnom obrascu promjene i najmanjem utjecaju distraktora prilikom pamćenja manjeg broja podražaja, u skladu s hipotezom da veća količina resursa pridana nekom podražaju ima protektivno ulogu.

Sljedeći korak u analizi rezultata prvog eksperimenta bio je provjera pristajanja hipotetiziranog modela mješovitih distribucija podacima. Podsjetimo, pretpostavljeni model opisuje dosjećanje uslijed prikaza distraktora pomoću točnih dosjećanja, slučajnih pogađanja, pogrešaka zamjena te intruzija. Ovaj model bolje je pristajao podacima od alternativnog modela i pokazao kako su pogreške zamjene i intruzije važni izvori pogrešaka dosjećanja. Analiza utjecaja snage distraktora uglavnom je pokazala konzistentan pad u vjerojatnosti točnog dosjećanja, ali taj pad nije konzistentno pratio porast samo jedne vrste pogrešaka. I slučajna pogađanja i pogreške zamjene varirale su u funkciji broja podražaja koji se pamtio, ali ne i u funkciji snage distraktora. Ove pogreške bile su podjednake uslijed prikaza distraktora onima opaženima u kontrolnoj situaciji. Intruzije su također rasle s porastom broja podražaja koji se pamtio, no djelomično iznenađujuće, bile su podjednako česte uslijed slabih i snažnih distraktora. Iako smo pokazali kako su pogreške zamjene i intruzije važne komponente uratka u zadatku VRP-a uz prikaz distraktora, važno je dodatno se osvrnuti na nalaze vezane uz ove parametre.

Pogreške zamjene smatraju se jednim od ključnih obilježja uratka u zadacima VRP-a (Schnegans i Bays, 2016). Nastanak ovih pogrešaka dominantno se interpretira kao posljedica nepreciznog kodiranja pojedinačnih karakteristika podražaja u jedinstvenu reprezentaciju. Specifično, pogreške zamjene u jednostavnom zadatku kontinuirane procjene posljedica su nepreciznog kodiranja karakteristike koja se pamti (npr. boje) i prostorne lokacije koja služi kao znak za dosjećanje. Jednako kao što su pojedine karakteristike podražaja (npr. boja) kodirane uz

određenu razinu neuralnog šuma, tako su i cjelovite reprezentacije (npr. boja i lokacija) opterećene neuralnim šumom. Prethodna istraživanja pokazala su kako su ove pogreške češće kada se pamti veći broj podražaja (Bays i sur., 2009; Schneegans i Bays, 2016), kada je prostorna udaljenost između lokacija podražaja (koje služe kao znak za dosjećanje) mala (Bays, 2016a; Emrich i Ferber, 2012; Rerko, Oberauer i Lin, 2014; Souza, Rerko, Lin i Oberauer, 2014) ili kada je bilo koja karakteristika podražaja koja služi kao znak za dosjećanje slična nekom drugom podražaju (npr. kod pamćenja podražaja s karakteristikama orijentacije i boje, kada se kao znak za dosjećanje koriste boje podražaja, a sudionik se treba dosjetiti orijentacije) (Oberauer i Lin, 2017; Schneegans i Bays, 2017a).

Pretpostavka važeća za sve eksperimente prikazane u ovom istraživanju bila je kako će prezentacija distraktora unijeti dodatni šum u povezivanje boja podražaja s odgovarajućom lokacijom, što će rezultirati porastom čestine pogrešaka zamjene. Prethodna istraživanja demonstrirala su kako je povezivanje karakteristika podražaja u jedinstveni objekt posebno osjetljivo na interferirajuće efekte distraktora, osjetljivije od pamćenja pojedinih karakteristika (Allen i sur., 2015; Ueno, Allen i sur., 2011; Ueno, Mate, Allen, Hitch i Baddeley, 2011). Naši rezultati nisu pokazali variranje pogrešaka zamjene u funkciji prikaza distraktora. Jedno moguće objašnjenje je kako smo distraktore prikazali izvan vremena potrebnog za stabilno povezivanje karakteristika podražaja u objekt. Prethodno navedena istraživanja koristila su znatno kraće vremenske intervale između prikaza podražaja za pamćenje i distraktora što bi moglo objasniti izostanak očekivanog efekta u prvom istraživanju (za usporedbu vidi posljednji eksperiment u ovom radu). Nadalje, neka istraživanja objašnjavaju pogreške zamjene kao posljedicu odvlačenja pažnje distraktorima od pamćenih podražaja, a ne okupiranja ograničenih resursa VRP-a (Brown i Brockmole, 2010; Fallon i sur., 2018). Ipak, istraživanja uglavnom pokazuju kako pažnja nije nužan uvjet za povezivanje svojstva u objekt (Delvenne, Cleeremans i Laloyaux, 2010; Vergauwe, Langerock i Barrouillet, 2014; Yeh, Yang i Chiu, 2005) čak niti kada je sukcesivno prikazana svojstva potrebno povezati u objekt (Karlsen, Allen, Baddeley i Hitch, 2010). S druge strane, sličnost distraktora, bilo po boji ili lokaciji, mogla bi objasniti nastanak ovih pogrešaka (Golomb, 2015). Iako u ovom radu nismo sustavno varirali sličnost boja i lokacija distraktora i podražaja za pamćenje, buduća istraživanja trebala bi posvetiti dodatnu pažnju upravo tome, te ispitati variraju li pogreške zamjene ovisno o sličnosti sadržaja VRP-a i distraktora, i to naročito izvan kratkog perioda potrebnog za povezivanje karakteristika podražaja u objekt. Na temelju prethodno navedenih istraživanja koja su pokazala variranje pogrešaka zamjene u funkciji sličnosti karakteristika podražaja koje služe kao znakovi za dosjećanje, ovaj smjer istraživanja čini se vrlo korisnim.

Druga specifična vrsta pogrešaka pretpostavljena za sve provedene eksperimente bila je pojava intruzija, odnosno navođenje boje jednog od distraktora prilikom dosjećanja tražene boje.

Ova vrsta pogrešaka prethodno je dominantno ispitivana u istraživanjima verbalnog i akustičkog radnog pamćenja (Atkins, Berman, Reuter-Lorenz, Lewis i Jonides, 2011; Bancroft, Jones, Ensor, Hockley i Servos, 2016; De Beni, Palladino, Pazzaglia i Cornoldi, 1998; Robert, Borella, Fagot, Lecerf i de Ribaupierre, 2009). U području VRP-a primarno su istraživane intruzije nastale kao posljedica proaktivne interferencije, tj. prethodno prikazanog ili naučenog materijala (Allen i sur., 2015; Hartshorne, 2008; Ueno, Mate i sur., 2011), a tek poneko istraživanje osvrnulo se i na intruzije nastale retroaktivno, tj. zbog podražaja prikazanih nakon kodiranja (Fallon i sur., 2018; van Ede, Chekroud i sur., 2018). U prvom eksperimentu opažene su značajne proporcije intruzija, pri čemu je čestina njihove pojave prelazila 10% kod pamćenja najdužih nizova. Ključno, pojava intruzija nije sustavno varirala s porastom snage distraktora. Ovaj nalaz posebno je zanimljiv jer pokazuje kako novi, ometajući vidni podražaj može zamijeniti reprezentaciju u VRP-u neovisno o svojoj snazi. Ipak, pojava intruzija varirala je sa snagom reprezentacija pri čemu je njihova čestina bila veća što su sudionici pamtili veći broj podražaja. Kao i u slučaju pogrešaka zamjene, pojava intruzija vjerojatno ovisi o sličnosti karakteristika sadržaja VRP-a i distraktora. U našem istraživanju to bi konkretno značilo prostorno preklapanje podražaja za pamćenje i distraktora. Iako nismo sustavno varirali prostorni razmještaj distraktora, jedno od zanimljivih istraživačkih pitanja je upravo kakva je uloga prostornog preklapanja distraktora i sadržaja VRP-a u pojavi intruzija.

U prvom eksperimentu jedna metoda manipulacije snage reprezentacije bila je korištenje različitog broja podražaja, uz pretpostavku raspodjela ograničenih resursa na veći broj podražaja dovodi do pada kvalitete pamćenja pojedinog podražaja, a s tim i preciznosti dosjećanja. Ovaj efekt broja podražaja ključan je nalaz u istraživanjima VRP-a (van den Berg i sur., 2014). Nekoliko autora predložilo je kako je relevantnost pojedinog podražaja (Palmer, 1994), definirana kao povišena vjerojatnost dosjećanja pojedinog podražaja u odnosu na preostale prikazane, važnija determinanta kvalitete reprezentacija (Emrich, Lockhart i Al-Aidroos, 2017; van den Berg i Ma, 2018). Kada je vjerojatnost dosjećanja svih podražaja jednaka, efekt broja podražaja (N) i vjerojatnost dosjećanja pojedinog podražaja ($1/N$) u potpunoj su korelaciji i jednako dobro objašnjavaju nalaze o padu uratka s rastom broja podražaja koji se pamti. Korištenjem signala unatrag vjerojatnost dosjećanja pojedinog podražaja se mijenja. Emrich i sur. (2017) proveli su istraživanje u kojem su manipulirali broj podražaja i pouzdanost signala unatrag kojim su sudionicima indicirali kojeg će se podražaja trebati dosjetiti. Rezultati njihovog istraživanja pokazali su kako je vjerojatnost traženja konkretnog podražaja za dosjećanje bolji prediktor uratka od broja podražaja koji se pamti. Ovaj nalaz potvrdili su van den Berg i Ma (2018) provjeravajući pristajanje neuralnog modela s implementiranom raspodjelom resursa na temelju relevantnosti podražaja podacima objavljenima u devet utjecajnih studija (za suprotne rezultate vidi Dube, Lumsden i Al-Aidroos, 2018).

Istraživanje korisnosti prediktivnih signala unatrag, tj. davanje prioriteta podražaju za dosjećanje, motiviralo je pojavu teorija koje pretpostavljaju višestruka stanja unutar VRP-a, primarno definirana fokusom pažnje (tzv. modeli jednog utora) (Myers, Chekroud, Stokes i Nobre, 2017; van Moorselaar, Olivers, Theeuwes, Lamme i Sligte, 2015; za suprotne nalaze vidi Bahle, Beck i Hollingworth, 2018). Nadalje, nekoliko istraživanja pokazalo je kako usmjeravanje pažnje nakon nestanka senzornog podraživanja može osnažiti reprezentaciju subliminalnih podražaja koji u suprotnom ostaju izvan dohvata za dosjećanje (Thibault, van den Berg, Cavanagh i Sergent, 2016; Wildegger, Humphreys i Nobre, 2016). Iako je pojava ove paradigme dovela do bitnih teorijskih razvoja u području VRP-a, istraživanja i dalje nisu suglasna oko načina na koji signal unatrag djeluje. Tipično, istraživanja pokazuju kako se utjecaj davanja prioriteta odražava ili u promjeni mnemoničke preciznosti (Gunseli i sur., 2015; Makovski i Pertzov, 2015; van Moorselaar, Gunseli i sur., 2015; Wallis, Stokes, Cousijn, Woolrich i Nobre, 2015; Williams i sur., 2013) ili porastu vjerojatnosti točnog dosjećanja (Gunseli i sur., 2015; Makovski i Pertzov, 2015; Murray, Nobre, Clark, Cravo i Stokes, 2013; Myers, Walther, Wallis, Stokes i Nobre, 2015; Souza, Rerko, Lin i Oberauer, 2014; Souza i sur., 2016; van Moorselaar, Gunseli i sur., 2015; Wallis i sur., 2015; Williams i sur., 2013). Wildegger i sur. (2016) su pokazali kako efekt signala barem u nekoj mjeri ovisi i o kvaliteti senzornog podraživanja, i to na način da davanje prioriteta povećava preciznost dosjećanja senzorno snažnih podražaja, dok za one slabe (npr. niskog kontrasta) povećava primarno vjerojatnost točnog dosjećanja.

U eksperimentu 2a davanje prioriteta jednom od zapamćenih podražaja za dosjećanje imalo je iznenađujuće efekte na uradak u zadatku, prvenstvenu u odnosu na prikazane distraktore. Kada sudionicima nisu prikazivani distraktori, dosjećanje je bilo bolje za prioritetne podražaje, i to kada su analizirale pogreške dosjećanja, vjerojatnost točnih dosjećanja, slučajna pogađanja i pogreške zamjene. Iako u istraživanju nije korištena kontrolna skupina bez signala unatrag, te ne možemo odgovoriti na pitanje postoji li benefit dosjećanja prioritetnih podražaja ili trošak dosjećanja neprioritetnih podražaja, opažene razlike su u skladu s prethodnim istraživanjima (Astle i sur., 2012; Gressmann i Janczyk, 2016; Gözenman, Tanoue, Metoyer i Berryhill, 2014; Pertzov i sur., 2013). Nadalje, ove razlike karakteristične su za korištenje visoko pouzdanih signala unatrag (Gunseli i sur., 2015) kakve su i korištene u eksperimentu 2a. Ključan nalaz bio je taj da je opaženi efekt prioriteta podražaja za dosjećanje ostao je prisutan čak i kada su sudionicima prikazivani distraktori različite snage. Konkretno, niti za prioritetne niti za neprioritetne podražaje, prikazivanje distraktora nije promijenilo pogrešku dosjećanja. Iako je hipotetizirani model mješovitih distribucija bolje pristajao podacima od alternativnog jednostavnog modela, parametri ovog modela varirali su samo u funkciji prioriteta za dosjećanje, ali ne i snage distraktora. Pritom, važno je izdvojiti nalaz vezan za intruzije koje su također varirale u funkciji prioriteta - intruzije distraktora u VRP bile su češće kod kod neprioritetnih podražaja u usporedbi s prioritetnim podražajima. Iako pogreška dosjećanja nije varirala u funkciji distraktora,

pojava intruzija pokazuje kako bi bilo pogrešno zaključiti da distraktori ne utječu na podražaje kada ih se jasno odvoji prioritetom za dosjećanje.

Prethodna istraživanja demonstrirala su kako davanje prioriteta podražaju za dosjećanje štiti od interferencije distraktorima i ubačenim zadacima (Hollingworth i Maxcey-Richard, 2013; Rerko, Souza i Oberauer, 2014), drugih zapamćenih podražaja (Gressmann i Janczyk, 2016; Souza, Rerko, Lin i Oberauer, 2014; Souza, Rerko i Oberauer, 2014; Vandenbroucke, Sligte, de Vries, Cohen i Lamme, 2015), te interferencije od testnog ekrana (Makovski i sur., 2008; Souza i sur., 2016; Wang i sur., 2018). Nadalje, istraživanja su pokazala kako distraktirajući prikaz ipak dovodi do lošijeg dosjećanja prioriternog podražaja u odnosu na dosjećanje istog podražaja bez prikaza distraktora, i to kada je kao distraktor korištena vidna pretraga (Hollingworth i Maxcey-Richard, 2013), procjena topline boje (Rerko, Souza i Oberauer, 2014), odluka o (ne)parnosti broja (Makovski i Pertzov, 2015), šareni irelevantni podražaji (Makovski, 2012), ili TMS podraživanje (Zokaei, Ning, Manohar, Feredoes i Husain, 2014). S druge strane, kada su kao distraktirajući podražaj korištena vidna svojstva identična onima koje su sudionici trebali pohraniti (boje), te zadatkom od sudionika nije traženo donošenje odluke koje može zamagliti ispitivane kognitivne procese, dosjećanje prioriternog podražaja bilo je jednako neovisno o prikazu distraktora (Makovski i Jiang, 2007). Podaci dobiveni eksperimentom 2a u skladu su s potonjim istraživanjem i našom pretpostavkom kako davanje prioriteta podražaju za dosjećanje osnažuje reprezentaciju i štiti je od distraktora. Važno je naglasiti kako su u našem istraživanju distraktori varirali u istom svojstvu kao i podražaji za pamćenje (boji), jednako kao u Makovski i Jiang (2007).

Većina istraživanja utjecaja distraktora i prioriternosti podražaja za dosjećanje koristila je potpuno pouzdane signale unatrag, tj. nisu ispitivali kakav je utjecaj distraktora na neprioriternne podražaje. Zokaei, Ning i sur. (2014) davali su prioritet podražajima za dosjećanje koristeći signale unatrag uz 80% pouzdanosti. Tijekom faze zadržavanja podraživali su senzorna područja TMS i pokazali kako je ovo podraživanje smanjivalo preciznost dosjećanja samo prioriternih, ali ne i neprioriternih podražaja. Autori su ove nalaze interpretirali kao dokaz u prilog hipotezi kako neprioriternni podražaji mijenjaju (neuralno) mjesto pohrane koje je izvan dohvata distraktirajućeg podraživanja senzornih područja. Christophel i sur. (2018) nedavno su ponudili jednu od prvih demonstracija kako vidni podražaji izvan fokusa pažnje doista ne dijele u potpunosti neuralnu lokaciju pohrane s podražajima u fokusu pažnje. Ovi autori pokazali su kako je prioriternne podražaje moguće dekodirati na temelju neuralnog signala opaženih u vidnim senzornim područjima, IPS i FEF; neprioriternne podražaje nije bilo moguće dekodirati iz vidnih područja. Drugo istraživanje, ono van Loon, Olmos-Solis, Fahrenfort i Olivers (2018), ponudilo je alternativno objašnjenje. Autori su od sudionika tražili da zapamte dva podražaja (npr. sliku cvijeta i krave) koje će morati koristiti u dvije nadolazeće vidne pretrage. Nakon zapamćivanja

podražaja, na svakoj sekvenci signalom unatrag naznačeno je koji će od dva podražaja biti korišten na prvoj (stanje slično prioritetnom podražaju za dosjećanje) a koji na drugoj (stanje slično neprioritetnom podražaju za dosjećanje) vidnoj pretrazi. Autori su pokazali kako su obrasci neuralne aktivnosti za dva podražaja tijekom prve vidne pretrage u, neočekivanoj, negativnoj korelaciji. U drugom eksperimentu uveli su dodatne manipulacije i pokazali kako je obrazac aktivnosti neprioritetnog podražaja specifičan za tu vrstu podražaja i različit od obrasca aktivnosti irelevantnog podražaja. Ukupno, ovo istraživanje pokazalo je kako su neprioritetni podražaji tijekom obavljanja zadatka pohranjeni u neuralnom kodu koji ih čuva za kasniju upotrebu i to u obliku koji je sustavno i predvidljivo različit od neuralnog koda prioritetnog podražaja. Ključno, najvažniji zaključak provedenog istraživanja jest kako je neuralni kod neprioritetnog podražaja sačuvan od interferencije. Iako smo za eksperiment 2a hipotezom pretpostavili kako snaga reprezentacije neprioritetnih podražaja pada zbog čega bi potencijalno mogli biti osjetljiviji na distraktore, naši rezultati su u skladu s nedavnim istraživanjima koja pokazuju kako perceptivni distraktori nemaju pristup neprioritetnim podražajima (Christophel i sur., 2018; van Loon i sur., 2018).

Davanje prioriteta podražajima za dosjećanje korištenjem visoko pouzdanih signala unazad kakve smo koristili u eksperimentu 2a pokazuje kakva je uloga *odozgo-prema-dolje* kognitivnih procesa. U svakodnevnim zadacima, osim upravljanja reprezentacijama ovisno o očekivanoj važnosti pojedinog podražaja za obavljanje tih zadataka, pojedini podražaji postanu salijentniji, a da se pritom ne mijenja njihova relevantnost za zadatak. Takvi okolinski znakovi potiču *odozdo-prema-gore* procese koji mogu utjecati na konačan uradak u dosjećanju podražaja iz VRP-a (Bays i sur., 2011). U eksperimentu 2b željeli smo provjeriti kakva je uloga *odozdo-prema-gore* procesa u obrani reprezentacija od distraktora. U tu svrhu, u svakoj sekvenci jedan od prikazanih podražaja osvježen je signalom unatrag. Ključno, prediktivnost tog signala bila je jednaka slučaju. Iako se osvježavanje tipično inducira uputom sudionicima da pomisle na signalizirani podražaj, Souza i sur. (2015) pokazali su kako je osvježavanje podražaja moguće i neprediktivnim signalima unatrag. Osim toga, bogat skup nalaza iz područja istraživanja pažnje pokazuje kako su čak i potpuno irelevantni podražaji otporni na ignoriranje te uspijevaju okupirati pažnju (engl. *attentional capture*; Folk i Remington, 1998; Forster i Lavie, 2008).

Istraživanja koja su koristila signale niske prediktivnosti demonstrirala su kako je dosjećanje osvježenih podražaja bolje u odnosu na kontrolnu situaciju bez signala, dok trošak za neosvježene podražaje gotovo da ne postoji (Gunseli i sur., 2015; Shimi, Nobre, Astle i Scerif, 2014; Souza i sur., 2015)). Također, pokazano je kako preciznost dosjećanja ovisi o broju osvježavanja i to na način da veći broj osvježavanja djeluje povoljno na uradak (Rerko i Oberauer, 2013; Souza i sur., 2015). Posebno impresivan nalaz je onaj Berryhill, Richmond, Shay i Olson (2012) koji su pokazali kako su dosjećanja bolja na sekvencama kada signal predviđa podražaj

za dosjećanje, čak i kada je ukupna pouzdanost signala iznimno niska te kada se sudionicima uputom izrazito kaže da ignoriraju signal unazad. Bolje pamćenje signaliziranih u odnosu na nesignalizirane podražaje ostaje prisutno čak i kada, prije dosjećanja, sudionici na pojedinoj sekvenci dobe uputu da zanemare prethodno prikazani signal unatrag (Li i Saiki, 2014).

Ipak, gotovo da ne postoje istraživanja koja su ispitivala ulogu osvježavanja podražaja u obrani reprezentacija od distraktora. Zokaei, Manohar, Husain i Feredoes (2014) od sudionika su tražili da zapamte smjer kretanja dva podražaja te se u fazi dosjećanja dosjete jednog od njih. U periodu zadržavanja sudionicima su prikazivali neprediktivne signale unatrag, a nakon toga ih podraživali TMS. U usporedbi s kontrolnom situacijom, uslijed TMS podraživanja preciznost dosjećanja za signalizirane (osvježene) podražaje je pala, dok je za nesignalizirane porasla. Autori su ovaj nalaz protumačili na način da TMS suprimira reprezentaciju signaliziranog podražaja, što smanjuje interferenciju za nesignalizirani podražaj i dovodi do bolje preciznosti dosjećanja. Rezultati dobiveni u našem radu djelomično su u skladu s onima Zokaei, Manohar i sur. (2014) (premda, treba imati na umu kako su naši distraktori i TMS podraživanje bitno različite metode interferiranja). Iako se osvježeni i neosvježeni podražaji u situaciji bez distraktora nisu razlikovali po pogrešci dosjećanja, vjerojatnosti točnog dosjećanja, pogađanjima niti pogreškama zamjene, prikaz distraktora različito je utjecao na osvježene i neosvježene podražaje. Konkretno, pogreška dosjećanja uslijed distraktora brže je rasla za neosvježeni u odnosu na osvježeni podražaj. S druge strane, pad u vjerojatnosti točnih dosjećanja i porast pogrešaka zamjene opažen je za neosvježene podražaje, ali ne i za osvježene podražaje. Drugim riječima, rezultati su bili u skladu s hipotezom prema kojoj veća snaga osvješanih podražaja djeluje protektivno od distraktirajućih podražaja. I u ovom eksperimentu, kao i u prethodnima, opažena je pojava intruzija; donekle neočekivano, njihova pojava bila je podjednaka neovisno o osvježavanju i snazi distraktora. Posebno zanimljiv je nalaz kako pretpostavljena snaga reprezentacije nije dovela do opazivih razlika u dosjećanju sve dok nije uveden distraktor. Prethodno, istraživanja su sugerirala kako osvježavanje, i na općenitijoj razini signali unatrag, štite podražaje od osipanja (Bays i Taylor, 2018; Pertzov i sur., 2013; Schneegans i Bays, 2017b). Naši rezultati proširuju ovaj mehanizam zaštite demonstrirajući i zaštitu od distraktora. Konačno, usporedimo li manipulacije i nalaze korištene u eksperimentima 2a i 2b, važno je naglasiti kako ovo istraživanje jasno razdvaja mehanizme davanja prioriteta za dosjećanje i osvježavanja podražaja, te njihove uloge u zaštiti reprezentacija od distraktora.

U svim do sada opisanim eksperimentima snaga reprezentacija u VRP-u manipulirana je količinom resursa koja je pridana podražaju te davanjem prioriteta ili osvježavanjem podražaja. U posljednjem provedenom eksperimentu snaga reprezentacija manipulirana je odabirom faze u kojoj je prikazan distraktor. Unazad nekoliko godina, u području VRP-a intenzivirala se debata oko neuralnog mjesta pohrane podražaja VRP-a. Danas dvije dominantne hipoteze pretpostav-

ljaju kako VRP koristi primarno vidna osjetna područja (Awh i Jonides, 2001; Emrich, 2015; Pasternak i sur., 2015; Sreenivasan i sur., 2014) odnosno prefrontalna (Durstewitz i sur., 2000; Mendoza-Halliday i sur., 2015; Riley i Constantinidis, 2016) ili parijetalna (Xu i Jeong, 2015) područja. Ako se pohrana doista odvija u vidnim osjetnim područjima (hipoteza senzornog regrutiranja), tada će dodatni angažman vidnih područja tijekom bilo koje faze obavljanja zadataka VRP-a imati posljedice na preciznost pohrane. S druge strane, ako se pohrana odvija u nekim drugim područjima mozga, tada će prikaz perceptivnih distraktora imati posljedice samo u onim fazama kada su osjetna područja nužna, npr. faza kodiranja. Rezultati posljednjeg eksperimenta u potpunosti su u skladu s drugom hipotezom. Konkretno, prikazivanje distraktora dovelo je do porasta pogreške dosjećanja, pada vjerojatnosti točnih dosjećanja te porasta pogrešaka zamjena i intruzija samo kada su distraktori bili prikazani neposredno nakon kodiranja. Ovi rezultati većim dijelom su u skladu i s nekim ranijim istraživanjima (van Ede, Chekroud i sur., 2018; van Lamsweerde i Johnson, 2017).

Pojava pogrešaka zamjena i intruzija u posljednjem eksperimentu pratila je promjene u padu vjerojatnosti točnog dosjećanja sustavnije nego u bilo kojem drugom eksperimentu. Ove pogreške u modelima utora svrstavaju se u slučajna pogađanja, dok se broj utora kojima osoba raspolaže procjenjuje preko vjerojatnosti točnog dosjećanja (1 - vjerojatnost pogađanja). Uzevši u obzir čestinu pojave ovih pogrešaka, vidljivo je kako modeli utora podcjenjuju sposobnost pamćenja. Pritom, posebno su važne pogreške zamjene jer nastaju dosjećanjem podražaja pohranjenih u VRP te bi trebale biti obuhvaćene procjenama ograničenosti VRP-a, neovisno o teorijskom modelu od kojeg se polazi. Rajsic i Wilson (2014) tražili su od sudionika da upamte boje i lokacije prikazanih podražaja, te kod dosjećanja tražili da se dosjete jednog od tih podražaja. Autori su u fazi dosjećanja sudionicima ponovno prikazali sve podražaje, izuzev onog traženog za dosjećanje. Rezultati su pokazali gotovo potpuni nestanak pogrešaka zamjene te značajan porast vjerojatnosti točnog dosjećanja u usporedbi sa situacijom kada je sudionicima prikazan samo tipičan znak za dosjećanje (boja ili lokacija). Rajsic, Swan, Wilson i Pratt (2017) su proširili ove nalaze i pokazali kako prikazivanje više znakova za dosjećanje (npr. i boje i lokacije) također povećava vjerojatnost točnog dosjećanja (npr. orijentacije) te smanjuje pogreške zamjene. Ova istraživanja dodatno demonstriraju kako pogreške zamjene obuhvaćaju stvarno pohranjene informacije u VRP-u. U posljednjem eksperimentu, procjene pogrešaka zamjene u fazi kodiranja kretale su se oko 20%, i to neovisno o snazi distraktora. Drugim riječima, distraktori su, neovisno o snazi uspjeli unijeti šum u povezivanje boja i lokacije u jedinstvenu reprezentaciju VRP-a. Ovaj nalaz suprotan je onima opaženima u istraživanju van Lamsweerde i Johnson (2017). U tom istraživanju, autori su pronašli utjecaj distraktora na uradak u ranim fazama kodiranja, ali ne i kada su analizirali pogreške zamjene. Konkretno, pogreške zamjene bile su podjednake neovisno o prikazu distraktora kao i vremenu prikaza. Jedna važna razlika između ovog i našeg istraživanja jest u vrsti korištenog distraktora. van Lamsweerde i John-

son (2017) su kao distraktor koristili maskirajući prikaz, podražaj vrlo sličan onome kakav je prikazivan nakon distraktirajućih boja. Podsjetimo, u kontrolnoj situaciji kada je sudionicima prikaza samo maska, bez distraktora, pogreške zamjene nisu se razlikovale između faza. Važno je i reći kako odabir maske kao distraktirajućeg podražaja ima vrlo malu ekološku valjanost - distraktori u svakodnevnim zadacima rijetko kada bude sličan nestrukturiranom šumu.

Istraživanja koja ne zagovaraju hipotezu senzornog regrutiranja svejedno pronalaze povećani angažman senzornih područja u fazi dosjećanja (Xu i Chun, 2006). Ovaj nalaz motivirao je hipotezu prema kojoj dosjećanje počiva na istim neuralnim područjima kao i kodiranje podražaja (Rugg i sur., 2008). Dodatan angažman tih područja distraktorima u fazi dosjećanja trebao bi dovesti do sličnih efekata kao i prikaz distraktora u fazi kodiranja. Ipak, u našem istraživanju nismo pronašli dokaze o postojanju interferencije u fazi dosjećanja. Kako reprezentacije u fazi dosjećanja uspijevaju biti otporne na iste distraktore koji u fazi kodiranja dovode do značajnog pada u preciznosti dosjećanja? Jedna važna razlika u prikazu distraktora kod ove dvije faze sastoji se u tome što, u fazi kodiranja, distraktori ulaze u vidni sustav u trenutku dok senzorno podraživanje nije pretvoreno u barem donekle stabilnu reprezentaciju. S druge strane, distraktori u fazi dosjećanja interferiraju s prizivanjem reprezentacije iz dosjećanja. I dok nakon nestanka senzornog podraživanja ne možemo više utjecati na preciznost kodiranja (osim narušiti ju distraktorima), istog podražaja iz VRP-a se možemo po potrebi dosjetiti više puta, npr. ako prvo dosjećanje iz bilo kojeg razloga bude ometeno.

Izostanak interferirajućeg efekta u fazi dosjećanja potencijalno se može objasniti činjenicom da je prikaz distraktora nakon znaka za dosjećanje stvorio situaciju interferencije uz pamćenje jednog podražaja. Kako je u prvom eksperimentu pokazano, uz manji broj objekata u VRP-u, možemo očekivati i manju interferenciju. Potencijalno, usporedba interferirajućeg efekta uz pamćenje tri podražaja (interferencija u prve dvije faze obrade) i pamćenje jednog podražaja (interferencija kod dosjećanja) može stvoriti privid izostanka efekta u potonjoj situaciji. Dva su argumenta protiv takvog objašnjenja. Prvo, pojava distraktora slijedila je odmah nakon znaka za dosjećanje čije je trajanje kao i u ostalim eksperimentima iznosilo 500ms. Iako ne postoje istraživanja koja su ispitivala vrijeme potrebno da se dozove podražaj iz VRP-a, nedavna istraživanja ispitivala su koliko vremena je potrebno za potpuno inkorporiranje informacija danih potpuno prediktivnim signalima unazad. Kada je signal unazad potpuno prediktivan, sudionici počinju s dosjećanjem odmah nakon prikaza signala unazad, a zatim čekaju s davanjem odgovora. Istraživanje van Moorselaar, Gunseli i sur. (2015) pokazalo je kako je u zadatku pamćenja orijentacija potrebno otprilike 600ms za potpuno prebacivanje internalne pažnje na signalizirani podražaj. Procjene drugih radova mnogo su konzervativnije i predlažu period od 1-2 sekunde (Shepherdson, Oberauer i Souza, 2017; Souza, Rerko i Oberauer, 2014). Iz svega navedenog, možemo biti dosta sigurni kako su distraktori prikazani u periodu dok su se sudi-

onici dosjećali podražaja. Drugo, sve ako su sudionici u potpunosti uspjeli dozvati podražaj iz VRP-a (tj. izbaciti preostale podražaje) prije samog prikaza distraktora, snaga reprezentacije dozvanog podražaja ne može biti usporediva snazi pamćenja samo jednog podražaja, ponajprije jer je ukupna količina resursa u fazi kodiranja podijeljena na tri jednaka dijela. Nakon što senzorno podraživanje nestane, ne postoji način na koji možemo poboljšati kvalitetu reprezentacije u odnosu na onu prilikom kodiranja.

U preostalim ovdje prikazanim eksperimentima, prezentiranje distraktora između 1 i 1.5 sekunde nakon niza za pamćenje, dovelo je do interferirajućeg utjecaja u dva od tri eksperimenta. Ovi rezultati nisu sasvim konzistentni sa zaključkom posljednjeg eksperimenta prema kojem samo distraktori u fazi kodiranja, ali ne i u fazi zadržavanja (2.5 sekunde nakon prikaza za pamćenje) dovode do interferirajućeg efekta. Jedno objašnjenje za ovakve naizgled neusklađene nalaze jest kako je VRP osjetljivo na distraktore tijekom faze kodiranja u širem smislu, tj. tijekom kodiranja i konsolidacije podražaja. U ranije opisanom istraživanju Nieuwenstein i Wyble (2014) procijenili su vrijeme kodiranja koristeći paradigme maskiranja i treptaj pažnje. Procjene potrebne za potpuno kodiranje i konsolidaciju dobivene u tom istraživanju dosezale su otprilike 1 sekundu, a ovdje prikazani rezultati konzistentni su s tim nalazom.

Kao alternativni model dosjećanja u ovom istraživanju korišten je jednostavni probabilistički model mješovitih distribucija konzistentan s novijim konceptualizacijama modela utora (Zhang i Luck, 2008). Takav model pokazao je, izuzev eksperimenta 2b, lošije pristajanje podacima od pretpostavljenog i složenijeg modela koji obuhvaća pogreške zamjena i intruzije. U eksperimentu 2b usporedba modela dala je prednost jednostavnijem modelu, iako, uz vrlo malu snagu dokaza u prilog tom modelu. Iako su modeli utora razmatrani korištenjem statističkog modela koji predstavlja zaštitni znak ove skupine modela VRP-a, iz teorijskog aspekta nije sasvim jasno kakve bi hipoteze očekivali prema modelima utora. Općenito, stariji modeli utora (Luck i Vogel, 1997) ne razmatraju koncepte poput snage reprezentacije u VRP-u, dok ih noviji (Zhang i Luck, 2008) razmatraju tek djelomično, kada zadatak zahtjeva pamćenje broja podražaja koji je manji od broja utora što dovodi do uprosječivanja preostalih utora i njihovo dijeljenje između zapamćenih podražaja. Nadalje, modeli utora nazivaju se još i "*sve-ili-ništa*" modeli, i to zbog pretpostavke da su, kada podražaj dobije utor, sve informacije o njemu zapamćene, odnosno da nikakav trag informacija ne postoji kada podražaj nije dobio svoj utor. Kako su prema modelima utora percepcija i VRP jasno odvojeni procesi, ponajprije činjenicom da VRP za razliku od percepcije funkcionira preko utora, najvjerodostojnija pretpostavka modela utora jest kako perceptivni distraktori nemaju pristup VRP-u. Ako ipak relaksiramo granicu između ovih procesa, pretpostavka modela utora je kako distraktori mogu utjecati na VRP samo ako dobiju utor ili "*izguraju*" podražaj izvan utora.

U našem istraživanju nekoliko je eksperimentalnih situacija u kojima su sudionici pamtiti

broj podražaja koji je manji ili jednak često navođenom kapacitetu VRP-a od 3-4 podražaja (eksperiment 1 izuzev situacije sa šest podražaja, te svi preostali eksperimenti). U tim situacijama svi prikazani podražaji trebali su dobiti svoj utor. Prikaz distraktora mogao je tada dovesti do nekoliko scenarija: a) podražaji u utorima mogli su ostati netaknuti; b) podražaji u pojedinim utorima mogli su biti izbrisani; c) distraktor je mogao istisnuti podražaj iz utora i zauzeti njegovo mjesto. U terminima modela mješovitih distribucija, scenarij a) pretpostavlja kako se dosjećanja mogu opisati jednom normalnom distribucijom (točna dosjećanja), scenarij b) normalnom (točna dosjećanja) i uniformnom (pogađanja) distribucijom, te c) scenarij dvije normalne distribucije, jedna centrirana na traženu vrijednost (točna dosjećanja) i druga centrirana na vrijednosti distraktora (intruzije). Formalno je testiran samo scenarij b) i u većini slučajeva pripadajući *normalna + uniformna* model pokazao je lošije pristajanje podacima. Iako ovdje nisu prikazani, modeli koji opisuju scenarije a) i c) pokazali su u svim situacijama lošije pristajanje od modela resursa predloženog u ovom radu. Loše pristajanje modela opisanih pod a) i c) očekivano je i zbog znatne količine pogrešaka zbog slučajnog pogađanja i pogrešaka zamjene procijenjenih u svim eksperimentima. Važno je reći i kako preostala dva scenarija (a i c) ovdje nisu detaljnije razmatrana jer ne postoji jasan teorijski okvir ili empirijski nalazi koji bi potkrijepili takve alternativne modele.

Općenita pretpostavka cijelog prikazanog istraživanja bila je kako će prezentacija distraktora djelovati na reprezentacije pohranjene u VRP-u te kako je VRP jedini mehanizam obrane pohranjenih reprezentacija od distraktora. Konkretno, pretpostavili smo kako je snaga reprezentacije determinanta otpornosti na distraktore. Iako smo prikazanim podacima snažno potvrdili ovu pretpostavku, moguće je kako postoje i drugi mehanizmi zaštite pohranjenih podražaja. Dvije istaknute hipoteze vezane uz ovu temu uključuju razmatranje trenutka u kojem se nevažni distraktori "isključuju" iz obrade. Prema hipotezi rane selekcije (Broadbent, 1958; Lachter, Forster i Ruthruff, 2004) za zadatak nevažne informacije isključuje se iz obrade vrlo rano, a tipičan nalaz koji potkrepljuje ovu hipotezu je onaj o izostanku identifikacije karakteristika podražaja kojima nije usmjerena pažnja. S druge strane, hipoteza kasne selekcije (de Fockert, 2013; Eriksen i Eriksen, 1974) temelji se na nalazima da irelevantni distraktori interferiraju s identifikacijom obilježja ciljnog podražaja što sugerira kako se distraktori obrađuju barem do neke razine. Pristup ovog rada više je u skladu s potonjom hipotezom prema kojoj se distraktori isključuju relativno kasno, nakon što informacije o njima budu barem djelomično kodirane.

Osim vremenskog tijeka interakcije distraktora i VRP-a, važno je pitanje kakav je efekt selekcije pažnjom, bila ona rana ili kasna, na sadržaj radnog pamćenja a kakav na distraktore. Konkretno, pažnja može utjecati zaštitom sadržaja VRP-a, inhibicijom distraktora, ili oboje (LaBerge, 1995). Prethodnim istraživanjima sugerirano je kako su sudionici s većim kapacitetom VRP-a uspješniji u zadatku VRP-a usprkos prikazu distraktora (Vogel i sur., 2005), a nedavna

istraživanja pripisala su taj uspjeh efikasnijem inhibiranju distraktora (Gaspar, Christie, Prime, Jolicœur i McDonald, 2016; ipak vidi Noonan i sur., 2016). Ovi nalazi utemeljeni su na pristupu modela utora i povezanom neuralnom indikatoru kojeg stariji modeli utora pretpostavljaju, specifično, CDA. Preostala istraživanja dodatnu ukazuju na kompleksnost ovog pitanja. Makovski (2018) je nedavno demonstrirao kako su sudionici brži u detekciji ciljnog podražaja (npr. točke na ekranu) tijekom zadatka VRP-a u situaciji prikazivanja distraktora nego u situaciji bez distraktora. Konkretno, u tipičnom zadatku detekcije promjene s prikazom distraktora, na nekim sekvencama sudionicima je iznenada prekinuta sekvenca i prikazana je točka na koju su morali reagirati. Rezultati su pokazali da sudionici brže reagiraju na ciljni podražaj kada je on prezentiran u sekvencama na kojima je trebao uslijediti prikaz distraktora. Autor je protumačio ove nalaze kao dokaz da sudionici alociraju dodatnu pažnju svakom nadolazećem podražaju. S druge strane, van Ede, Quinn, Woolrich i Nobre (2018), pokazali su kako signaliziranje da će se na sekvenci pojaviti distraktor dovodi do preciznijeg dosjećanja u usporedbi sa situacijom kada prikaz distraktora nije bio signaliziran unaprijed. Ukratko, čini se kako jasan odgovor na pitanje u ulozi pažnje u obrani sadržaja VRP-a od distraktora za sada ne postoji.

Iako modeli resursa ne pretpostavljaju poseban mehanizam zaštite reprezentacija ili inhibicije distraktora, eksperimentalna provjera ovih hipoteza mogla bi biti vrlo jednostavna. Ako postoji mehanizam odvojen od VRP-a, njegovo uključivanje u zadatak trebalo bi pratiti neku optimalnu strategiju, tj. takav mehanizam trebao bi se češće uključivati kada postoji veća potreba za njim (npr. kada su distraktori česti). U zadatku u kojem bi se varirala čestina prikaza distraktora u sekvencama (npr. prikaz distraktora u 10%, 50% i 90% sekvenci unutar pojedinog bloka) možemo očekivati da bi se i mehanizam zaštite i mehanizam inhibicije u većoj mjeri uključivali uz češću pojavu distraktora. Važno, uradak bi trebao biti pod utjecajem takvog mehanizma neovisno o tome je li distraktor prikazan ili ne (trebao bi ovisiti samo o vjerojatnosti prikaza distraktora). Drugim riječima, ako VRP štiti reprezentacije od distraktora, tada bi porast u uratku s povećanjem vjerojatnosti prikaza distraktora trebao biti vidljiv i na sekvencama na kojima nije prikazan distraktor. S druge strane, inhibicija distraktora trebala bi biti vidljiva u poboljšanju uratka s porastom vjerojatnosti prikaza distaktora i to na sekvencama na kojima je prikazan distraktor.

Na apstraktnijoj razini, nekoliko istraživanja sugeriralo je kako su perceptivni procesi i procesi VRP-a bitno isprepleteniji no što to istraživanja tipično pretpostavljaju, pritom stavljajući poseban fokus na senzornu snagu informacija koja se može percipirati odnosno pohraniti u VRP. Konkretno, predloženo je kako VRP može funkcionirati na nesvjesnoj razini, tj. pohranjivati i obrađivati subliminalne informacije bez svjesnog pristupa tim informacijama (Charles, Van Opstal, Marti i Dehaene, 2013; Dutta, Shah, Silvanto i Soto, 2014; Hassin, Bargh, Engell i McCulloch, 2009; Jacobs i Silvanto, 2015; Soto, Mäntylä i Silvanto, 2011; Trübutschek i sur.,

2017). Ova istraživanja daju mnogo važniju ulogu nesvjesnim informacijama u ljudskom kognitivnom sustavu od ranije opisanih istraživanja interferirajućih efekata subliminalnih distraktora. Nadalje, istraživanja su pokazala kako subliminalne informacije koje se podudaraju s trenutnim sadržajem VRP-a brže dolaze do svjesne razine (Gayet, Paffen i Van der Stigchel, 2013). Iako će ovo pitanje biti predmet testiranja budućih istraživanja, nekoliko nedavnih pregleda istraživanja "nesvjesnog" radnog pamćenja zaključilo je kako ne postoji snažan nalaz u prilog takvom spremniku pamćenja (Persuh, LaRock i Berger, 2018) te da se nalazi ovih istraživanja mogu objasniti postojećim konceptima nesvjesne percepcije i svjesnog radnog pamćenja (Stein, Kaiser i Hesselmann, 2016). Na primjer, Bays (2016b) i Tomić i Bays (2018) su pokazali kako se resursi u VRP-u distribuiraju proporcionalno senzornoj snazi podražaja (manipuliranoj kontrastom podražaja), te da modeli koji pretpostavljaju neku vrstu probabilističkog kodiranja na temelju apsolutnog praga pokazuju inferiorno pristajanje u usporedbi s modelima kontinuirane raspodjele resursa. Imajući na umu ove nalaze, jedan od načina na koji bi se spoznaje o "nesvjesnom" VRP-u mogle integrirati u trenutne spoznaje o VRP-u (primarno modelima resursa) jest njihovo razmatranje u terminima TDS koja pretpostavlja kontinuiran odnos snage podražaja i doživljaja. Takav pristup razmatrao bi i snagu podražaja i raspodjelu resursa u terminima kontinuuma, bez potrebe za dodatnom podjelom VRP-a na spremnike informacija karakterizirane stupnjevima različite svijesti.

7 Zaključak

U provedenom istraživanju cilj je bio provjeriti kakva je uloga snage distraktora u preciznosti pamćenja podražaja različite snage reprezentacija pohranjenih u VRP-u. Kroz sve provedene eksperimente potvrdili smo očekivanu pretpostavku kako distraktori manje utječu na dosjećanje podražaja čije su reprezentacije snažne, u odnosu na podražaje s manjom snagom, tj. kvalitetom reprezentacija u VRP-u. Snažnije reprezentacije podražaja formirane su pridavanjem veće količine resursa (eksperiment 1: pamćenje manjeg broja podražaja uz duže vrijeme kodiranja), davanjem prioriteta podražaju za dosjećanje (eksperiment 2a: prikaz prediktivnih signala unatrag), osvježavanjem podražaja (eksperiment 2b: prikaz neprediktivnih signala unazad), ili formiranjem stabilne reprezentacije (eksperiment 3: prikaz distraktora izvan rane faze obrade).

Iako je u istraživanju pronađen utjecaj snage distraktora, tj. razlika između utjecaja slabih i snažnih distraktora, on je uvelike ovisio o načinu na koji je snaga reprezentacije manipulirana. Kada je snaga reprezentacije manipulirana količinom pridanih resursa (eksperiment 1) ili trenutnim osvježavanjem podražaja (eksperiment 2b), distraktori različite snage u različitoj su mjeri narušili kvalitetu reprezentacija u VRP-u. Kada je snaga reprezentacije manipulirana trajnim određivanjem prioriteta za dosjećanje (eksperiment 2a), distraktori nisu utjecali na kvalitetu reprezentacije. Konačno, kada su distraktori prikazani u ranim fazama formiranja reprezentacije, dok resursi nisu alocirani u odgovarajućoj mjeri, distraktori su, neovisno o svojoj snazi, bitno narušili kvalitetu reprezentacije.

Modeliranje pogrešaka dosjećanja probabilističkim modelom mješovitih distribucija pokazalo je kako se dosjećanja uslijed prikaza distraktora mogu vrlo dobro opisati modelom koji pretpostavlja četiri komponente odgovora: točna dosjećanja, slučajna pogađanja, pogreške zamjene i intruzije. Utjecaj distraktora dominantno se odrazio na smanjenju vjerojatnosti točnih dosjećanja, premda su i promjene tog parametra ovisile su o vrsti manipulacije snage reprezentacije. Promjene vjerojatnosti točnih dosjećanja uglavnom se nisu dosljedno odrazile (izuzev eksperimenta 3) u specifičnim pogreškama dosjećanja. Vrlo važan je nalaz je onaj kako su se pogreške intruzije u svim eksperimentima (izuzev 2b gdje je opažena granično neznačajni efekt) varirali u funkciji snage reprezentacije u VRP-u. Konkretno, što je snaga reprezentacije veća, postoji manja vjerojatnost da ju novi, irelevantni podražaj istisne i zamijeni u VRP-u.

8 Literatura

- Aagten-Murphy, D. i Bays, P. M. (2017). Automatic and intentional influences on saccade landing. *Journal of Neurophysiology*, *118*(2), 1105–1122.
- Aagten-Murphy, D. i Bays, P. M. (2018). Functions of Memory Across Saccadic Eye Movements. Berlin, Heidelberg: Springer Berlin Heidelberg. doi: 10.1007/7854_2018_66
- Abrahamyan, A., Clifford, C. W. G., Arabzadeh, E. i Harris, J. A. (2011). Improving Visual Sensitivity with Subthreshold Transcranial Magnetic Stimulation. *Journal of Neuroscience*, *31*(9), 3290–3294. doi: 10.1523/JNEUROSCI.6256-10.2011
- Adam, K., Robison, M. K. i Vogel, E. K. (2018). Contralateral Delay Activity Tracks Fluctuations in Working Memory Performance. *Journal of Cognitive Neuroscience*, 1–12.
- Adam, K., Vogel, E. K. i Awh, E. (2017). Clear evidence for item limits in visual working memory. *Cognitive Psychology*, *97*, 79–97. doi: 10.1016/j.cogpsych.2017.07.001
- Albers, A., Kok, P., Toni, I., Dijkerman, H. i de Lange, F. (2013). Shared Representations for Working Memory and Mental Imagery in Early Visual Cortex. *Current Biology*, *23*(15), 1427–1431. doi: 10.1016/j.cub.2013.05.065
- Allefeld, C. i Haynes, J.-D. (2014). Searchlight-based multi-voxel pattern analysis of fMRI by cross-validated MANOVA. *NeuroImage*, *89*, 345–357. doi: 10.1016/j.neuroimage.2013.11.043
- Allen, R. J., Baddeley, A. D. i Hitch, G. J. (2006). Is the binding of visual features in working memory resource-demanding? *Journal of Experimental Psychology: General*, *135*(2), 298–313. doi: 10.1037/0096-3445.135.2.298
- Allen, R. J., Baddeley, A. D. i Hitch, G. J. (2017). Executive and perceptual distraction in visual working memory. *Journal of Experimental Psychology: Human Perception and Performance*, *43*(9), 1677–1693. doi: 10.1037/xhp0000413
- Allen, R. J., Castellà, J., Ueno, T., Hitch, G. J. i Baddeley, A. D. (2015). What does visual suffix interference tell us about spatial location in working memory? *Memory & Cognition*, *43*(1), 133–142. doi: 10.3758/s13421-014-0448-4
- Almeida, R., Barbosa, J. i Compte, A. (2015). Neural circuit basis of visuo-spatial working memory precision: a computational and behavioral study. *Journal of Neurophysiology*, *114*(3), 1806–1818. doi: 10.1152/jn.00362.2015
- Alvarez, G. i Cavanagh, P. (2004). The Capacity of Visual Short-Term Memory is Set Both by Visual Information Load and by Number of Objects. *Psychological Science*, *15*(2), 106–111. doi: 10.1111/j.0963-7214.2004.01502006.x
- Aron, A. R., Robbins, T. W. i Poldrack, R. A. (2004). Inhibition and the right inferior frontal cortex. *Trends in Cognitive Sciences*, *8*(4), 170–177. doi: 10.1016/j.tics.2004.02.010
- Asplund, C. L., Fougnie, D., Zughni, S., Martin, J. W. i Marois, R. (2014). The Attentional

- Blink Reveals the Probabilistic Nature of Discrete Conscious Perception. *Psychological Science*, 25(3), 824–831. doi: 10.1177/0956797613513810
- Astle, D. E., Summerfield, J., Griffin, I. i Nobre, A. C. (2012). Orienting attention to locations in mental representations. *Attention, Perception, & Psychophysics*, 74(1), 146–162. doi: 10.3758/s13414-011-0218-3
- Atkins, A. S., Berman, M. G., Reuter-Lorenz, P. A., Lewis, R. L. i Jonides, J. (2011). Resolving semantic and proactive interference in memory over the short-term. *Memory & Cognition*, 39(5), 806–817. doi: 10.3758/s13421-011-0072-5
- Atkinson, R. i Shiffrin, R. (1968). Human Memory: A Proposed System and its Control Processes. U: *Psychology of Learning and Motivation* (Vol. 2, str. 89–195). Elsevier. Retrieved from [2016-09-16]<http://linkinghub.elsevier.com/retrieve/pii/S0079742108604223>
- Awh, E., Barton, B. i Vogel, E. K. (2007). Visual Working Memory Represents a Fixed Number of Items Regardless of Complexity. *Psychological Science*, 18(7), 622–628. doi: 10.1111/j.1467-9280.2007.01949.x
- Awh, E. i Jonides, J. (2001). Overlapping mechanisms of attention and spatial working memory. *Trends in Cognitive Sciences*, 5(3), 119–126. doi: 10.1016/S1364-6613(00)01593-X
- Baars, B. J. i Gage, N. M. (2010). Neurons and their connections. U: *Cognition, Brain, and Consciousness* (str. 62–92). Elsevier. doi: 10.1016/B978-0-12-375070-9.00003-6
- Bae, G.-Y., Olkkonen, M., Allred, S. R., Wilson, C. i Flombaum, J. I. (2014). Stimulus-specific variability in color working memory with delayed estimation. *Journal of Vision*, 14(4), 7–7. doi: 10.1167/14.4.7
- Bahcall, D. O. i Kowler, E. (1999). Attentional interference at small spatial separations. *Vision Research*, 39(1), 71–86. doi: 10.1016/S0042-6989(98)00090-X
- Bahle, B., Beck, V. M. i Hollingworth, A. (2018). The architecture of interaction between visual working memory and visual attention. *Journal of Experimental Psychology: Human Perception and Performance*. doi: 10.1037/xhp0000509
- Balan, P. F., Oristaglio, J., Schneider, D. M. i Gottlieb, J. (2008). Neuronal Correlates of the Set-Size Effect in Monkey Lateral Intraparietal Area. *PLoS Biology*, 6(7), e158. doi: 10.1371/journal.pbio.0060158
- Balsdon, T. i Clifford, C. W. G. (2018). Visual processing: conscious until proven otherwise. *Royal Society Open Science*, 5(1), 171783. doi: 10.1098/rsos.171783
- Bancroft, T. D., Jones, J. A., Ensor, T. M., Hockley, W. E. i Servos, P. (2016). Overwriting and intrusion in short-term memory. *Memory & Cognition*, 44(3), 435–443. doi: 10.3758/s13421-015-0570-y
- Barlow, H. (1961). Possible Principles Underlying the Transformations of Sensory Messages. U: W. A. Rosenblith (Ur.), *Sensory Communication* (str. 216–234). The MIT Press. doi:

10.7551/mitpress/9780262518420.003.0013

- Bashinski, H. S. i Bacharach, V. R. (1980). Enhancement of perceptual sensitivity as the result of selectively attending to spatial locations. *Perception & Psychophysics*, 28(3), 241–248.
- Basso, M. A. i Wurtz, R. H. (1998). Modulation of neuronal activity in superior colliculus by changes in target probability. *The Journal of Neuroscience: The Official Journal of the Society for Neuroscience*, 18(18), 7519–7534.
- Bays, P. M. (2014). Noise in Neural Populations Accounts for Errors in Working Memory. *Journal of Neuroscience*, 34(10), 3632–3645.
- Bays, P. M. (2015). Spikes not slots: noise in neural populations limits working memory. *Trends in Cognitive Sciences*, 19(8), 431–438. doi: 10.1016/j.tics.2015.06.004
- Bays, P. M. (2016a). Evaluating and excluding swap errors in analogue tests of working memory. *Scientific Reports*, 6, 19203. doi: 10.1038/srep19203
- Bays, P. M. (2016b). A signature of neural coding at human perceptual limits. *Journal of Vision*, 16(11), 4. doi: 10.1167/16.11.4
- Bays, P. M. (2018a). Failure of self-consistency in the discrete resource model of visual working memory. *Cognitive Psychology*, 105, 1–8. doi: 10.1016/j.cogpsych.2018.05.002
- Bays, P. M. (2018b). Reassessing the Evidence for Capacity Limits in Neural Signals Related to Working Memory. *Cerebral Cortex*. doi: 10.1093/cercor/bhx351
- Bays, P. M., Catalao, R. F. G. i Husain, M. (2009). The precision of visual working memory is set by allocation of a shared resource. *Journal of Vision*, 9(10), 7–7. doi: 10.1167/9.10.7
- Bays, P. M. i Dowding, B. A. (2017). Fidelity of the representation of value in decision-making. *PLOS Computational Biology*, 13(3), e1005405. doi: 10.1371/journal.pcbi.1005405
- Bays, P. M., Gorgoraptis, N., Wee, N., Marshall, L. i Husain, M. (2011). Temporal dynamics of encoding, storage, and reallocation of visual working memory. *Journal of Vision*, 11(10), 6–6. doi: 10.1167/11.10.6
- Bays, P. M. i Husain, M. (2008). Dynamic Shifts of Limited Working Memory Resources in Human Vision. *Science*, 321(5890), 851–854. doi: 10.1126/science.1158023
- Bays, P. M. i Taylor, R. (2018). A neural model of retrospective attention in visual working memory. *Cognitive Psychology*, 100, 43–52. doi: 10.1016/j.cogpsych.2017.12.001
- Becke, A., Müller, N., Vellage, A., Schoenfeld, M. A. i Hopf, J.-M. (2015). Neural sources of visual working memory maintenance in human parietal and ventral extrastriate visual cortex. *NeuroImage*, 110, 78–86. doi: 10.1016/j.neuroimage.2015.01.059
- Becker, M. W., Miller, J. R. i Liu, T. (2013). A severe capacity limit in the consolidation of orientation information into visual short-term memory. *Attention, Perception, & Psychophysics*, 75(3), 415–425. doi: 10.3758/s13414-012-0410-0
- Beckers, G. i Hömberg, V. (1991). Impairment of visual perception and visual short term

- memory scanning by transcranial magnetic stimulation of occipital cortex. *Experimental Brain Research*, 87(2). doi: 10.1007/BF00231859
- Bennett, P. J. i Cortese, F. (1996). Masking of spatial frequency in visual memory depends on distal, not retinal, frequency. *Vision Research*, 36(2), 233–238. doi: 10.1016/0042-6989(95)00085-E
- Berryhill, M. E., Richmond, L. L., Shay, C. S. i Olson, I. R. (2012). Shifting Attention among Working Memory Representations: Testing Cue Type, Awareness, and Strategic Control. *Quarterly Journal of Experimental Psychology*, 65(3), 426–438. doi: 10.1080/17470218.2011.604786
- Bettencourt, K. C. i Xu, Y. (2016). Decoding the content of visual short-term memory under distraction in occipital and parietal areas. *Nature Neuroscience*, 19(1), 150–157. doi: 10.1038/nn.4174
- Bona, S., Cattaneo, Z., Vecchi, T., Soto, D. i Silvanto, J. (2013). Metacognition of Visual Short-Term Memory: Dissociation between Objective and Subjective Components of VSTM. *Frontiers in Psychology*, 4, 62.
- Bona, S. i Silvanto, J. (2014). Accuracy and Confidence of Visual Short-Term Memory Do Not Go Hand-In-Hand: Behavioral and Neural Dissociations. *PLoS ONE*, 9(3), e90808. doi: 10.1371/journal.pone.0090808
- Bonfond, M. i Jensen, O. (2012). Alpha Oscillations Serve to Protect Working Memory Maintenance against Anticipated Distracters. *Current Biology*, 22(20), 1969–1974. doi: 10.1016/j.cub.2012.08.029
- Bouchacourt, F. i Buschman, T. J. (2018). A Flexible Model of Working Memory. doi: 10.1101/407700
- Brady, T. F., Konkle, T. i Alvarez, G. A. (2011). A review of visual memory capacity: Beyond individual items and toward structured representations. *Journal of Vision*, 11(5), 4–4. doi: 10.1167/11.5.4
- Brady, T. F., Konkle, T., Gill, J., Oliva, A. i Alvarez, G. A. (2013). Visual Long-Term Memory Has the Same Limit on Fidelity as Visual Working Memory. *Psychological Science*, 24(6), 981–990. doi: 10.1177/0956797612465439
- Brady, T. F. i Tenenbaum, J. B. (2013). A probabilistic model of visual working memory: Incorporating higher order regularities into working memory capacity estimates. *Psychological Review*, 120(1), 85–109. doi: 10.1037/a0030779
- Breitmeyer, B. G. i Ogmen, H. (2000). Recent models and findings in visual backward masking: a comparison, review, and update. *Perception & Psychophysics*, 62(8), 1572–1595.
- Breitmeyer, B. G. i Ogmen, H. (2006). *Visual Masking*. Oxford University Press. Retrieved from [2016-04-25]<http://www.oxfordscholarship.com/view/10.1093/acprof:oso/9780198530671.001.0001/acprof-9780198530671>

- Broadbent, D. E. (1958). *Perception and communication*. Elmsford: Pergamon Press. doi: 10.1037/10037-000
- Broadbent, D. E. i Broadbent, M. H. P. (1981). Recency effects in visual memory. *The Quarterly Journal of Experimental Psychology Section A*, 33(1), 1–15. doi: 10.1080/14640748108400762
- Brockmole, J. R., Wang, R. F. i Irwin, D. E. (2002). Temporal integration between visual images and visual percepts. *Journal of Experimental Psychology: Human Perception and Performance*, 28(2), 315–334. doi: 10.1037/0096-1523.28.2.315
- Brown, L. A. i Brockmole, J. R. (2010). The Role of Attention in Binding Visual Features in Working Memory: Evidence from Cognitive Ageing. *Quarterly Journal of Experimental Psychology*, 63(10), 2067–2079. doi: 10.1080/17470211003721675
- Bullier, J. (2001). Integrated model of visual processing. *Brain Research. Brain Research Reviews*, 36(2-3), 96–107.
- Bundesen, C. (1990). A theory of visual attention. *Psychological Review*, 97(4), 523–547. doi: 10.1037/0033-295X.97.4.523
- Carandini, M. i Heeger, D. J. (2011). Normalization as a canonical neural computation. *Nature Reviews Neuroscience*, 13(1). doi: 10.1038/nrn3136
- Carpenter, R. H. (2000). The neural control of looking. *Current biology: CB*, 10(8), R291–293.
- Carrasco, M., Penpeci-Talgar, C. i Eckstein, M. (2000). Spatial covert attention increases contrast sensitivity across the CSF: support for signal enhancement. *Vision Research*, 40(10-12), 1203–1215. doi: 10.1016/S0042-6989(00)00024-9
- Cattaneo, Z., Pisoni, A., Papagno, C. i Silvanto, J. (2011). Modulation of Visual Cortical Excitability by Working Memory: Effect of Luminance Contrast of Mental Imagery. *Frontiers in Psychology*, 2. doi: 10.3389/fpsyg.2011.00029
- Cattaneo, Z., Vecchi, T., Pascual-Leone, A. i Silvanto, J. (2009). Contrasting early visual cortical activation states causally involved in visual imagery and short-term memory: Visual imagery and memory. *European Journal of Neuroscience*, 30(7), 1393–1400. doi: 10.1111/j.1460-9568.2009.06911.x
- Charles, L., Van Opstal, F., Marti, S. i Dehaene, S. (2013). Distinct brain mechanisms for conscious versus subliminal error detection. *NeuroImage*, 73, 80–94. doi: 10.1016/j.neuroimage.2013.01.054
- Christophel, T. B. i Haynes, J.-D. (2014). Decoding complex flow-field patterns in visual working memory. *NeuroImage*, 91, 43–51. doi: 10.1016/j.neuroimage.2014.01.025
- Christophel, T. B., Hebart, M. N. i Haynes, J.-D. (2012). Decoding the Contents of Visual Short-Term Memory from Human Visual and Parietal Cortex. *Journal of Neuroscience*, 32(38), 12983–12989.

- Christophel, T. B., Iamshchinina, P., Yan, C., Allefeld, C. i Haynes, J.-D. (2018). Cortical specialization for attended versus unattended working memory. *Nature Neuroscience*. doi: 10.1038/s41593-018-0094-4
- Christophel, T. B., Klink, P. C., Spitzer, B., Roelfsema, P. R. i Haynes, J.-D. (2017). The Distributed Nature of Working Memory. *Trends in Cognitive Sciences*, 21(2), 111–124. doi: 10.1016/j.tics.2016.12.007
- Chun, M. M. i Potter, M. C. (1995). A two-stage model for multiple target detection in rapid serial visual presentation. *Journal of Experimental Psychology. Human Perception and Performance*, 21(1), 109–127.
- Churchland, A. K., Kiani, R. i Shadlen, M. N. (2008). Decision-making with multiple alternatives. *Nature Neuroscience*, 11(6), 693–702. doi: 10.1038/nn.2123
- Clapp, W. C., Rubens, M. T. i Gazzaley, A. (2010). Mechanisms of Working Memory Disruption by External Interference. *Cerebral Cortex*, 20(4), 859–872. doi: 10.1093/cercor/bhp150
- Cohen, M. R. i Maunsell, J. H. R. (2009). Attention improves performance primarily by reducing interneuronal correlations. *Nature Neuroscience*, 12(12), 1594–1600. doi: 10.1038/nn.2439
- Cohen-Dallal, H., Fradkin, I. i Pertzov, Y. (2018). Are stronger memories forgotten more slowly? No evidence that memory strength influences the rate of forgetting. *PLOS ONE*, 13(7), e0200292. doi: 10.1371/journal.pone.0200292
- Constantinidis, C., Funahashi, S., Lee, D., Murray, J. D., Qi, X.-L., Wang, M. i Arnsten, A. F. (2018). Persistent Spiking Activity Underlies Working Memory. *The Journal of Neuroscience*, 38(32), 7020–7028. doi: 10.1523/JNEUROSCI.2486-17.2018
- Coren, S. i Hoenig, P. (1972). Effect of Non-Target Stimuli upon Length of Voluntary Saccades. *Perceptual and Motor Skills*, 34(2), 499–508. doi: 10.2466/pms.1972.34.2.499
- Cowan, N. (2001). The magical number 4 in short-term memory: a reconsideration of mental storage capacity. *The Behavioral and Brain Sciences*, 24(1), 87–114; discussion 114–185.
- Cowan, N. (2005). *Working memory capacity*. Hove, East Sussex, UK: Psychology Press.
- Curby, K. M. i Gauthier, I. (2007). A visual short-term memory advantage for faces. *Psychonomic Bulletin & Review*, 14(4), 620–628.
- Dalmajer, E. S., Manohar, S. G. i Husain, M. (2018). Parallel encoding of information into visual short-term memory. doi: 10.1101/398990
- De Beni, R., Palladino, P., Pazzaglia, F. i Cornoldi, C. (1998). Increases in Intrusion Errors and Working Memory Deficit of Poor Comprehenders. *The Quarterly Journal of Experimental Psychology Section A*, 51(2), 305–320. doi: 10.1080/713755761
- de Fockert, J. W. (2013). Beyond perceptual load and dilution: a review of the role of

- working memory in selective attention. *Frontiers in Psychology*, 4. doi: 10.3389/fpsyg.2013.00287
- de Gardelle, V., Kouider, S. i Sackur, J. (2010). An oblique illusion modulated by visibility: Non-monotonic sensory integration in orientation processing. *Journal of Vision*, 10(10), 6–6. doi: 10.1167/10.10.6
- Dehaene, S., Changeux, J.-P., Naccache, L., Sackur, J. i Sergent, C. (2006). Conscious, pre-conscious, and subliminal processing: a testable taxonomy. *Trends in Cognitive Sciences*, 10(5), 204–211.
- Della Sala, S., Gray, C., Baddeley, A., Allamano, N. i Wilson, L. (1999). Pattern span: a tool for unwelding visuo-spatial memory. *Neuropsychologia*, 37(10), 1189–1199.
- Delvenne, J.-F., Cleeremans, A. i Laloyaux, C. (2010). Feature Bindings Are Maintained in Visual Short-Term Memory Without Sustained Focused Attention. *Experimental Psychology*, 57(2), 108–116. doi: 10.1027/1618-3169/a000014
- Derrfuss, J., Ekman, M., Hanke, M., Tittgemeyer, M. i Fiebach, C. J. (2017). Distractor-resistant Short-Term Memory Is Supported by Transient Changes in Neural Stimulus Representations. *Journal of Cognitive Neuroscience*, 29(9), 1547–1565. doi: 10.1162/jocn_a_01141
- D’Esposito, M., Postle, B., Ballard, D. i Lease, J. (1999). Maintenance versus Manipulation of Information Held in Working Memory: An Event-Related fMRI Study. *Brain and Cognition*, 41(1), 66–86. doi: 10.1006/brcg.1999.1096
- D’Esposito, M. i Postle, B. R. (2015). The Cognitive Neuroscience of Working Memory. *Annual Review of Psychology*, 66(1), 115–142. doi: 10.1146/annurev-psych-010814-015031
- D’Esposito, M., Postle, B. R., Jonides, J. i Smith, E. E. (1999). The neural substrate and temporal dynamics of interference effects in working memory as revealed by event-related functional MRI. *Proceedings of the National Academy of Sciences*, 96(13), 7514–7519. doi: 10.1073/pnas.96.13.7514
- Dickey, J. M. (1971). The Weighted Likelihood Ratio, Linear Hypotheses on Normal Location Parameters. *The Annals of Mathematical Statistics*, 42(1), 204–223. doi: 10.1214/aoms/1177693507
- Dolcos, F., Miller, B., Kragel, P., Jha, A. i McCarthy, G. (2007). Regional brain differences in the effect of distraction during the delay interval of a working memory task. *Brain Research*, 1152, 171–181. doi: 10.1016/j.brainres.2007.03.059
- Donkin, C., Kary, A., Tahir, F. i Taylor, R. (2016). Resources masquerading as slots: Flexible allocation of visual working memory. *Cognitive Psychology*, 85, 30–42. doi: 10.1016/j.cogpsych.2016.01.002
- Downing, P. E. (2000). Interactions between visual working memory and selective attention. *Psychological Science*, 11(6), 467–473.

- Drew, T. i Vogel, E. K. (2008). Neural Measures of Individual Differences in Selecting and Tracking Multiple Moving Objects. *Journal of Neuroscience*, 28(16), 4183–4191. doi: 10.1523/JNEUROSCI.0556-08.2008
- Dube, B., Lumsden, A. i Al-Aidroos, N. (2018). Probabilistic retro-cues do not determine state in visual working memory. *Psychonomic Bulletin & Review*. doi: 10.3758/s13423-018-1533-7
- Dubois, J., de Berker, A. O. i Tsao, D. Y. (2015). Single-Unit Recordings in the Macaque Face Patch System Reveal Limitations of fMRI MVPA. *Journal of Neuroscience*, 35(6), 2791–2802. doi: 10.1523/JNEUROSCI.4037-14.2015
- Dubé, C., Zhou, F., Kahana, M. J. i Sekuler, R. (2014). Similarity-based distortion of visual short-term memory is due to perceptual averaging. *Vision Research*, 96, 8–16. doi: 10.1016/j.visres.2013.12.016
- Durstewitz, D., Seamans, J. K. i Sejnowski, T. J. (2000). Dopamine-Mediated Stabilization of Delay-Period Activity in a Network Model of Prefrontal Cortex. *Journal of Neurophysiology*, 83(3), 1733–1750. doi: 10.1152/jn.2000.83.3.1733
- Dutta, A., Shah, K., Silvanto, J. i Soto, D. (2014). Neural basis of non-conscious visual working memory. *NeuroImage*, 91, 336–343. doi: 10.1016/j.neuroimage.2014.01.016
- Emrich, S. M. (2015). What are the Roles of Sensory and Parietal Activity in Visual Short-Term Memory? U: *Mechanisms of Sensory Working Memory* (str. 59–73). Elsevier. doi: 10.1016/B978-0-12-801371-7.00006-5
- Emrich, S. M. i Ferber, S. (2012). Competition increases binding errors in visual working memory. *Journal of Vision*, 12(4), 12–12. doi: 10.1167/12.4.12
- Emrich, S. M., Lockhart, H. A. i Al-Aidroos, N. (2017). Attention mediates the flexible allocation of visual working memory resources. *Journal of Experimental Psychology: Human Perception and Performance*, 43(7), 1454–1465. doi: 10.1037/xhp0000398
- Emrich, S. M., Riggall, A. C., LaRocque, J. J. i Postle, B. R. (2013). Distributed Patterns of Activity in Sensory Cortex Reflect the Precision of Multiple Items Maintained in Visual Short-Term Memory. *Journal of Neuroscience*, 33(15), 6516–6523.
- Eng, H. Y., Chen, D. i Jiang, Y. (2005). Visual working memory for simple and complex visual stimuli. *Psychonomic Bulletin & Review*, 12(6), 1127–1133.
- Eriksen, B. i Eriksen, C. W. (1974). Effects of noise letters upon identification of a target letter in a non- search task. *Perception & Psychophysics*, 16, 143–149.
- Ester, E., Sprague, T. i Serences, J. (2015). Parietal and Frontal Cortex Encode Stimulus-Specific Mnemonic Representations during Visual Working Memory. *Neuron*, 87(4), 893–905. doi: 10.1016/j.neuron.2015.07.013
- Ester, E. F., Anderson, D. E., Serences, J. T. i Awh, E. (2013). A Neural Measure of Precision in Visual Working Memory. *Journal of Cognitive Neuroscience*, 25(5), 754–761.

- Ester, E. F., Nouri, A. i Rodriguez, L. (2018). Retrospective Cues Mitigate Information Loss in Human Cortex during Working Memory Storage. *The Journal of Neuroscience*, 38(40), 8538–8548. doi: 10.1523/JNEUROSCI.1566-18.2018
- Ester, E. F., Rademaker, R. L. i Sprague, T. C. (2016). How Do Visual and Parietal Cortex Contribute to Visual Short-Term Memory? *eNeuro*, 3(2). doi: 10.1523/ENEURO.0041-16.2016
- Ester, E. F., Serences, J. T. i Awh, E. (2009). Spatially Global Representations in Human Primary Visual Cortex during Working Memory Maintenance. *Journal of Neuroscience*, 29(48), 15258–15265.
- Etz, A. i Vandekerckhove, J. (2018). Introduction to Bayesian Inference for Psychology. *Psychonomic Bulletin & Review*, 25(1), 5–34. doi: 10.3758/s13423-017-1262-3
- Faisal, A. A., Selen, L. P. J. i Wolpert, D. M. (2008). Noise in the nervous system. *Nature Reviews Neuroscience*, 9(4), 292–303. doi: 10.1038/nrn2258
- Fallon, S. J., Mattiesing, R. M., Dolfen, N., Manohar, S. i Husain, M. (2018). Ignoring versus updating in working memory reveal differential roles of attention and feature binding. *Cortex*, 107, 50–63. doi: 10.1016/j.cortex.2017.12.016
- Feredoes, E., Heinen, K., Weiskopf, N., Ruff, C. i Driver, J. (2011). Causal evidence for frontal involvement in memory target maintenance by posterior brain areas during distracter interference of visual working memory. *Proceedings of the National Academy of Sciences*, 108(42), 17510–17515. doi: 10.1073/pnas.1106439108
- Foley, J. M. i Legge, G. E. (1981). Contrast detection and near-threshold discrimination in human vision. *Vision Research*, 21(7), 1041–1053. doi: 10.1016/0042-6989(81)90009-2
- Folk, C. L. i Remington, R. (1998). Selectivity in distraction by irrelevant featural singletons: evidence for two forms of attentional capture. *Journal of Experimental Psychology: Human Perception and Performance*, 24(3), 847–858.
- Forster, S. i Lavie, N. (2008). Attentional capture by entirely irrelevant distractors. *Visual Cognition*, 16(2-3), 200–214. doi: 10.1080/13506280701465049
- Fougnie, D. (2009). The relationship between attention and working memory. U: N. Johansen (Ur.), *New research on short-term memory* (str. 1–45). New York: Nova Science.
- Fougnie, D., Cormiea, S. M., Kanabar, A. i Alvarez, G. A. (2016). Strategic trade-offs between quantity and quality in working memory. *Journal of Experimental Psychology: Human Perception and Performance*, 42(8), 1231–1240. doi: 10.1037/xhp0000211
- Fougnie, D., Suchow, J. W. i Alvarez, G. A. (2012). Variability in the quality of visual working memory. *Nature Communications*, 3, 1229. doi: 10.1038/ncomms2237
- Fuster, J. M. i Bressler, S. L. (2012). Cognit activation: a mechanism enabling temporal integration in working memory. *Trends in Cognitive Sciences*, 16(4), 207–218. doi: 10.1016/j.tics.2012.03.005

- Gaspar, J. M., Christie, G. J., Prime, D. J., Jolicœur, P. i McDonald, J. J. (2016). Inability to suppress salient distractors predicts low visual working memory capacity. *Proceedings of the National Academy of Sciences*, *113*(13), 3693–3698. doi: 10.1073/pnas.1523471113
- Gayet, S., Paffen, C. L. i Van der Stigchel, S. (2017). Visual Working Memory Storage Recruits Sensory Processing Areas. *Trends in Cognitive Sciences*. doi: 10.1016/j.tics.2017.09.011
- Gayet, S., Paffen, C. L. E. i Van der Stigchel, S. (2013). Information Matching the Content of Visual Working Memory Is Prioritized for Conscious Access. *Psychological Science*, *24*(12), 2472–2480. doi: 10.1177/0956797613495882
- Gegenfurtner, K. R. i Sperling, G. (1993). Information transfer in iconic memory experiments. *Journal of Experimental Psychology. Human Perception and Performance*, *19*(4), 845–866.
- Girshick, A. R., Landy, M. S. i Simoncelli, E. P. (2011). Cardinal rules: visual orientation perception reflects knowledge of environmental statistics. *Nature Neuroscience*, *14*(7), 926–932. doi: 10.1038/nn.2831
- Gold, J. I. i Shadlen, M. N. (2001). Neural computations that underlie decisions about sensory stimuli. *Trends in Cognitive Sciences*, *5*(1), 10–16. doi: 10.1016/S1364-6613(00)01567-9
- Gold, J. I. i Shadlen, M. N. (2007). The Neural Basis of Decision Making. *Annual Review of Neuroscience*, *30*(1), 535–574. doi: 10.1146/annurev.neuro.29.051605.113038
- Golomb, J. D. (2015). Divided spatial attention and feature-mixing errors. *Attention, Perception, & Psychophysics*, *77*(8), 2562–2569. doi: 10.3758/s13414-015-0951-0
- Gorgoraptis, N., Catalao, R. F. G., Bays, P. M. i Husain, M. (2011). Dynamic Updating of Working Memory Resources for Visual Objects. *Journal of Neuroscience*, *31*(23), 8502–8511. doi: 10.1523/JNEUROSCI.0208-11.2011
- Gosseries, O., Yu, Q., LaRocque, J. J., Starrett, M. J., Rose, N. S., Cowan, N. i Postle, B. R. (2018). Parietal-Occipital Interactions Underlying Control- and Representation-Related Processes in Working Memory for Nonspatial Visual Features. *The Journal of Neuroscience*, *38*(18), 4357–4366. doi: 10.1523/JNEUROSCI.2747-17.2018
- Green, D. M. i Swets, J. A. (1966). *Signal detection theory and psychophysics*. New York: Wiley.
- Green, M. F., Glahn, D., Engel, S. A., Nuechterlein, K. H., Sabb, F., Strojwas, M. i Cohen, M. S. (2005). Regional Brain Activity Associated with Visual Backward Masking. *Journal of Cognitive Neuroscience*, *17*(1), 13–23. doi: 10.1162/0898929052880011
- Green, M. F., Lee, J., Cohen, M. S., Engel, S. A., Korb, A. S., Nuechterlein, K. H., . . . Glahn, D. C. (2009). Functional Neuroanatomy of Visual Masking Deficits in Schizophrenia. *Archives of General Psychiatry*, *66*(12), 1295. doi: 10.1001/archgenpsychiatry.2009.132
- Gressmann, M. i Janczyk, M. (2016). The (Un)Clear Effects of Invalid Retro-Cues. *Frontiers*

- in Psychology*, 7. doi: 10.3389/fpsyg.2016.00244
- Griffin, I. C. i Nobre, A. C. (2003). Orienting Attention to Locations in Internal Representations. *Journal of Cognitive Neuroscience*, 15(8), 1176–1194. doi: 10.1162/089892903322598139
- Gunseli, E., Fahrenfort, J. J., van Moorselaar, D., Daoultzis, K. C. C., Meeter, M. i Olivers, C. N. L. (2018). Unattended but actively stored: EEG dynamics reveal a dissociation between selective attention and storage in working memory. doi: 10.1101/320952
- Gunseli, E., van Moorselaar, D., Meeter, M. i Olivers, C. N. L. (2015). The reliability of retro-cues determines the fate of noncued visual working memory representations. *Psychonomic Bulletin & Review*, 22(5), 1334–1341. doi: 10.3758/s13423-014-0796-x
- Gözenman, F., Tanoue, R. T., Metoyer, T. i Berryhill, M. E. (2014). Invalid retro-cues can eliminate the retro-cue benefit: Evidence for a hybridized account. *Journal of Experimental Psychology: Human Perception and Performance*, 40(5), 1748–1754. doi: 10.1037/a0037474
- Hao, R., Becker, M. W., Ye, C., Liu, Q. i Liu, T. (2018). The bandwidth of VWM consolidation varies with the stimulus feature: Evidence from event-related potentials. *Journal of Experimental Psychology: Human Perception and Performance*, 44(5), 767–777. doi: 10.1037/xhp0000488
- Hardman, K. O., Vergauwe, E. i Ricker, T. J. (2017). Categorical working memory representations are used in delayed estimation of continuous colors. *Journal of Experimental Psychology: Human Perception and Performance*, 43(1), 30–54. doi: 10.1037/xhp0000290
- Harris, J. A., Clifford, C. W. G. i Miniussi, C. (2008). The Functional Effect of Transcranial Magnetic Stimulation: Signal Suppression or Neural Noise Generation? *Journal of Cognitive Neuroscience*, 20(4), 734–740. doi: 10.1162/jocn.2008.20048
- Harrison, S. A. i Tong, F. (2009). Decoding reveals the contents of visual working memory in early visual areas. *Nature*, 458(7238), 632–635. doi: 10.1038/nature07832
- Harrison, W. J. i Bays, P. M. (2018). Visual Working Memory Is Independent of the Cortical Spacing Between Memoranda. *The Journal of Neuroscience*, 38(12), 3116–3123. doi: 10.1523/JNEUROSCI.2645-17.2017
- Hartshorne, J. K. (2008). Visual Working Memory Capacity and Proactive Interference. *PLoS ONE*, 3(7), e2716. doi: 10.1371/journal.pone.0002716
- Hassin, R. R., Bargh, J. A., Engell, A. D. i McCulloch, K. C. (2009). Implicit working memory. *Consciousness and Cognition*, 18(3), 665–678. doi: 10.1016/j.concog.2009.04.003
- Haxby, J. V. (2001). Distributed and Overlapping Representations of Faces and Objects in Ventral Temporal Cortex. *Science*, 293(5539), 2425–2430. doi: 10.1126/science.1063736
- Haynes, J.-D., Driver, J. i Rees, G. (2005). Visibility Reflects Dynamic Changes of Effective Connectivity between V1 and Fusiform Cortex. *Neuron*, 46(5), 811–821. doi: 10.1016/

j.neuron.2005.05.012

- Hecker, R. i Mapperson, B. (1997). Dissociation of visual and spatial processing in working memory. *Neuropsychologia*, 35(5), 599–603.
- Herwig, A., Beisert, M. i Schneider, W. X. (2010). On the spatial interaction of visual working memory and attention: evidence for a global effect from memory-guided saccades. *Journal of Vision*, 10(5), 8.
- Hoffman, J. E. (1979). A two-stage model of visual search. *Perception & Psychophysics*, 25(4), 319–327. doi: 10.3758/BF03198811
- Hollingworth, A., Matsukura, M. i Luck, S. J. (2013). Visual working memory modulates low-level saccade target selection: Evidence from rapidly generated saccades in the global effect paradigm. *Journal of Vision*, 13(13), 4–4. doi: 10.1167/13.13.4
- Hollingworth, A. i Maxcey-Richard, A. M. (2013). Selective maintenance in visual working memory does not require sustained visual attention. *Journal of Experimental Psychology: Human Perception and Performance*, 39(4), 1047–1058. doi: 10.1037/a0030238
- Huang, J. (2010). Distortions in recall from visual memory: Two classes of attractors at work. *Journal of Vision*, 10(2), 1–27. doi: 10.1167/10.2.24
- Irwin, D. E. (1991). Information integration across saccadic eye movements. *Cognitive Psychology*, 23(3), 420–456.
- Irwin, D. E. (1996). Integrating Information Across Saccadic Eye Movements. *Current Directions in Psychological Science*, 5(3), 94–100. doi: 10.1111/1467-8721.ep10772833
- Jacobs, C. i Silvanto, J. (2015). How is working memory content consciously experienced? The ‘conscious copy’ model of WM introspection. *Neuroscience & Biobehavioral Reviews*, 55, 510–519. doi: 10.1016/j.neubiorev.2015.06.003
- Jeong, S. K. i Xu, Y. (2013). Neural Representation of Targets and Distractors during Object Individuation and Identification. *Journal of Cognitive Neuroscience*, 25(1), 117–126. doi: 10.1162/jocn_a_00298
- Jerde, T. A., Merriam, E. P., Riggall, A. C., Hedges, J. H. i Curtis, C. E. (2012). Prioritized Maps of Space in Human Frontoparietal Cortex. *Journal of Neuroscience*, 32(48), 17382–17390.
- Jha, A. P., Fabian, S. A. i Aguirre, G. K. (2004). The role of prefrontal cortex in resolving distractor interference. *Cognitive, Affective & Behavioral Neuroscience*, 4(4), 517–527.
- Jiang, Y. i Kumar, A. (2004). Visual short-term memory for two sequential arrays: one integrated representation or two separate representations? *Psychonomic Bulletin & Review*, 11(3), 495–500.
- Johnson, J. S., Simmering, V. R. i Buss, A. T. (2014). Beyond slots and resources: Grounding cognitive concepts in neural dynamics. *Attention, Perception, & Psychophysics*, 76(6), 1630–1654. doi: 10.3758/s13414-013-0596-9

- Juslin, P., Nilsson, H., Winman, A. i Lindskog, M. (2011). Reducing cognitive biases in probabilistic reasoning by the use of logarithm formats. *Cognition*, *120*(2), 248–267. doi: 10.1016/j.cognition.2011.05.004
- Karlsen, P. J., Allen, R. J., Baddeley, A. D. i Hitch, G. J. (2010). Binding across space and time in visual working memory. *Memory & Cognition*, *38*(3), 292–303. doi: 10.3758/MC.38.3.292
- Kaswan, J. i Young, S. (1963). Stimulus exposure time, brightness, and spatial factors as determinants of visual perception. *Journal of Experimental Psychology*, *65*, 113–123.
- Keshvari, S., van den Berg, R. i Ma, W. J. (2012). Probabilistic Computation in Human Perception under Variability in Encoding Precision. *PLoS ONE*, *7*(6), e40216. doi: 10.1371/journal.pone.0040216
- Keshvari, S., van den Berg, R. i Ma, W. J. (2013). No Evidence for an Item Limit in Change Detection. *PLoS Computational Biology*, *9*(2), e1002927. doi: 10.1371/journal.pcbi.1002927
- Kiyonaga, A. i Egner, T. (2016). Center-Surround Inhibition in Working Memory. *Current Biology*, *26*(1), 64–68. doi: 10.1016/j.cub.2015.11.013
- Kiyonaga, A., Scimeca, J. M., Bliss, D. P. i Whitney, D. (2017). Serial Dependence across Perception, Attention, and Memory. *Trends in Cognitive Sciences*, *21*(7), 493–497. doi: 10.1016/j.tics.2017.04.011
- Klauer, K. C. i Zhao, Z. (2004). Double Dissociations in Visual and Spatial Short-Term Memory. *Journal of Experimental Psychology: General*, *133*(3), 355–381. doi: 10.1037/0096-3445.133.3.355
- Konstantinou, N., Beal, E., King, J.-R. i Lavie, N. (2014). Working memory load and distraction: dissociable effects of visual maintenance and cognitive control. *Attention, Perception, & Psychophysics*, *76*(7), 1985–1997. doi: 10.3758/s13414-014-0742-z
- Kruschke, J. K. i Liddell, T. M. (2018). Bayesian data analysis for newcomers. *Psychonomic Bulletin & Review*, *25*(1), 155–177. doi: 10.3758/s13423-017-1272-1
- Kundu, B., Sutterer, D. W., Emrich, S. M. i Postle, B. R. (2013). Strengthened Effective Connectivity Underlies Transfer of Working Memory Training to Tests of Short-Term Memory and Attention. *Journal of Neuroscience*, *33*(20), 8705–8715. doi: 10.1523/JNEUROSCI.5565-12.2013
- LaBerge, D. (1995). *Attentional processing: the brain's art of mindfulness*. Cambridge, Mass.: Harvard University Press. (OCLC: 623416202) Retrieved from [2018-12-11]<http://books.google.com/books?id=--xqAAAAMAAJ>
- Lachter, J., Forster, K. I. i Ruthruff, E. (2004). Forty-five years after Broadbent (1958): Still no identification without attention. *Psychological Review*, *111*(4), 880–913. doi: 10.1037/0033-295X.111.4.880

- Lalonde, J. i Chaudhuri, A. (2002). Task-dependent transfer of perceptual to memory representations during delayed spatial frequency discrimination. *Vision Research*, 42(14), 1759–1769. doi: 10.1016/S0042-6989(02)00111-6
- Lamme, V. A. (2003). Why visual attention and awareness are different. *Trends in Cognitive Sciences*, 7(1), 12–18. doi: 10.1016/S1364-6613(02)00013-X
- Lamme, V. A. i Roelfsema, P. R. (2000). The distinct modes of vision offered by feedforward and recurrent processing. *Trends in Neurosciences*, 23(11), 571–579.
- Landman, R., Spekreijse, H. i Lamme, V. A. F. (2003). Large capacity storage of integrated objects before change blindness. *Vision Research*, 43(2), 149–164.
- LaRocque, J. J., Lewis-Peacock, J. A., Drysdale, A. T., Oberauer, K. i Postle, B. R. (2013). Decoding Attended Information in Short-term Memory: An EEG Study. *Journal of Cognitive Neuroscience*, 25(1), 127–142. doi: 10.1162/jocn_a_00305
- LaRocque, J. J., Riggall, A. C., Emrich, S. M. i Postle, B. R. (2017). Within-Category Decoding of Information in Different Attentional States in Short-Term Memory. *Cerebral Cortex*, 27(10), 4881–4890.
- Lavie, N. (2005). Distracted and confused?: Selective attention under load. *Trends in Cognitive Sciences*, 9(2), 75–82. doi: 10.1016/j.tics.2004.12.004
- Lavie, N. i Tsal, Y. (1994). Perceptual load as a major determinant of the locus of selection in visual attention. *Perception & Psychophysics*, 56(2), 183–197.
- Lee, S.-H., Kravitz, D. J. i Baker, C. I. (2013). Goal-dependent dissociation of visual and prefrontal cortices during working memory. *Nature Neuroscience*, 16(8), 997–999. doi: 10.1038/nn.3452
- Lewis-Peacock, J. A., Drysdale, A. T., Oberauer, K. i Postle, B. R. (2012). Neural Evidence for a Distinction between Short-term Memory and the Focus of Attention. *Journal of Cognitive Neuroscience*, 24(1), 61–79.
- Lewis-Peacock, J. A., Kessler, Y. i Oberauer, K. (2018). The removal of information from working memory: The removal of information from working memory. *Annals of the New York Academy of Sciences*, 1424(1), 33–44. doi: 10.1111/nyas.13714
- Li, Q. i Saiki, J. (2014). The effects of sequential attention shifts within visual working memory. *Frontiers in Psychology*, 5. doi: 10.3389/fpsyg.2014.00965
- Li, Q. i Saiki, J. (2015). Different effects of color-based and location-based selection on visual working memory. *Attention, Perception, & Psychophysics*, 77(2), 450–463. doi: 10.3758/s13414-014-0775-3
- Livingstone, M. S. i Hubel, D. H. (1987). Psychophysical evidence for separate channels for the perception of form, color, movement, and depth. *The Journal of Neuroscience: The Official Journal of the Society for Neuroscience*, 7(11), 3416–3468.
- Logie, R. H., Brockmole, J. R. i Vandenbroucke, A. R. E. (2009). Bound feature combina-

- tions in visual short-term memory are fragile but influence long-term learning. *Visual Cognition*, 17(1-2), 160–179. doi: 10.1080/13506280802228411
- Logie, R. H. i Marchetti, C. (1991). Visuo-spatial working memory: Visual, spatial or central executive? U: R. H. Logie i D. Michel (Ur.), *Mental Images in Human Cognition* (Vol. 80, str. 105–115). Elsevier. Retrieved from [2016-09-16]<http://linkinghub.elsevier.com/retrieve/pii/S0166411508605075>
- Logothetis, N. K. (2008). What we can do and what we cannot do with fMRI. *Nature*, 453(7197), 869–878. doi: 10.1038/nature06976
- Lorenc, E. S., Sreenivasan, K. K., Nee, D. E., Vandenbroucke, A. R. E. i D’Esposito, M. (2018). Flexible coding of visual working memory representations during distraction. *The Journal of Neuroscience*, 3061–17. doi: 10.1523/JNEUROSCI.3061-17.2018
- Luck, S. J. i Vogel, E. K. (1997). The capacity of visual working memory for features and conjunctions. *Nature*, 390(6657), 279–281.
- Lundqvist, M., Herman, P. i Miller, E. K. (2018). Working Memory: Delay Activity, Yes! Persistent Activity? Maybe Not. *The Journal of Neuroscience*, 38(32), 7013–7019. doi: 10.1523/JNEUROSCI.2485-17.2018
- Luria, R., Balaban, H., Awh, E. i Vogel, E. K. (2016). The contralateral delay activity as a neural measure of visual working memory. *Neuroscience & Biobehavioral Reviews*, 62, 100–108. doi: 10.1016/j.neubiorev.2016.01.003
- Ma, W. J. (2018). Problematic usage of the Zhang and Luck mixture model. , –. doi: 10.1101/268961
- Ma, W. J., Husain, M. i Bays, P. M. (2014). Changing concepts of working memory. *Nature Neuroscience*, 17(3), 347–356. doi: 10.1038/nn.3655
- Macmillan, N. A. i Creelman, C. D. (2005). *Detection theory: a user’s guide* (2nd ed ed.). Mahwah, N.J: Lawrence Erlbaum Associates.
- Macoveanu, J., Klingberg, T. i Tegnér, J. (2007). Neuronal firing rates account for distractor effects on mnemonic accuracy in a visuo-spatial working memory task. *Biological Cybernetics*, 96(4), 407–419. doi: 10.1007/s00422-006-0139-8
- Magnussen, S. i Greenlee, M. W. (1992). Retention and disruption of motion information in visual short-term memory. *Journal of Experimental Psychology. Learning, Memory, and Cognition*, 18(1), 151–156.
- Magnussen, S. i Greenlee, M. W. (1999). The psychophysics of perceptual memory. *Psychological Research*, 62(2-3), 81–92.
- Magnussen, S., Greenlee, M. W., Asplund, R. i Dyrnes, S. (1991). Stimulus-specific mechanisms of visual short-term memory. *Vision Research*, 31(7-8), 1213–1219.
- Makovski, T. (2012). Are multiple visual short-term memory storages necessary to explain the retro-cue effect? *Psychonomic Bulletin & Review*, 19(3), 470–476. doi: 10.3758/

- Makovski, T. (2018). Preparing for distraction: Attention is enhanced prior to the presentation of distractors. *Journal of Experimental Psychology: General*. doi: 10.1037/xge0000509
- Makovski, T. i Jiang, Y. V. (2007). Distributing versus focusing attention in visual short-term memory. *Psychonomic Bulletin & Review*, *14*(6), 1072–1078. doi: 10.3758/BF03193093
- Makovski, T. i Pertzov, Y. (2015). Attention and memory protection: Interactions between retrospective attention cueing and interference. *The Quarterly Journal of Experimental Psychology*, *68*(9), 1735–1743. doi: 10.1080/17470218.2015.1049623
- Makovski, T., Shim, W. M. i Jiang, Y. V. (2006). Interference from filled delays on visual change detection. *Journal of Vision*, *6*(12), 11–11. doi: 10.1167/6.12.11
- Makovski, T., Sussman, R. i Jiang, Y. V. (2008). Orienting attention in visual working memory reduces interference from memory probes. *Journal of Experimental Psychology: Learning, Memory, and Cognition*, *34*(2), 369–380. doi: 10.1037/0278-7393.34.2.369
- Mathôt, S., Hickey, C. i Theeuwes, J. (2010). From reorienting of attention to biased competition: Evidence from hemifield effects. *Attention, Perception, & Psychophysics*, *72*(3), 651–657. doi: 10.3758/APP.72.3.651
- Matsukura, M., Luck, S. J. i Vecera, S. P. (2007). Attention effects during visual short-term memory maintenance: Protection or prioritization? *Perception & Psychophysics*, *69*(8), 1422–1434. doi: 10.3758/BF03192957
- Matthey, L., Bays, P. M. i Dayan, P. (2015). A Probabilistic Palimpsest Model of Visual Short-term Memory. *PLOS Computational Biology*, *11*(1), e1004003. doi: 10.1371/journal.pcbi.1004003
- Mazyar, H., van den Berg, R. i Ma, W. J. (2012). Does precision decrease with set size? *Journal of Vision*, *12*(6), 10–10. doi: 10.1167/12.6.10
- Mazyar, H., van den Berg, R., Seilheimer, R. L. i Ma, W. J. (2013). Independence is elusive: Set size effects on encoding precision in visual search. *Journal of Vision*, *13*(5), 8–8. doi: 10.1167/13.5.8
- McKeefry, D., Burton, M. i Vakrou, C. (2007). Speed selectivity in visual short term memory for motion. *Vision Research*, *47*(18), 2418–2425. doi: 10.1016/j.visres.2007.05.011
- McLachlan, G. J. i Peel, D. (2000). *Finite mixture models*. New York: Wiley.
- McNab, F., Zeidman, P., Rutledge, R. B., Smittenaar, P., Brown, H. R., Adams, R. A. i Dolan, R. J. (2015). Age-related changes in working memory and the ability to ignore distraction. *Proceedings of the National Academy of Sciences*, *112*(20), 6515–6518. doi: 10.1073/pnas.1504162112
- Mendoza, D., Schneiderman, M., Kaul, C. i Martinez-Trujillo, J. (2011). Combined effects of feature-based working memory and feature-based attention on the perception of visual motion direction. *Journal of Vision*, *11*(1), 11.

- Mendoza-Halliday, D., Torres, S. i Martinez-Trujillo, J. (2015). Working Memory Representations of Visual Motion along the Primate Dorsal Visual Pathway. U: *Mechanisms of Sensory Working Memory* (str. 159–169). Elsevier. doi: 10.1016/B978-0-12-801371-7.00013-2
- Miller, G. A. (1956). The magical number seven plus or minus two: some limits on our capacity for processing information. *Psychological Review*, 63(2), 81–97.
- Mirpour, K. i Bisley, J. W. (2012). Dissociating activity in the lateral intraparietal area from value using a visual foraging task. *Proceedings of the National Academy of Sciences*, 109(25), 10083–10088. doi: 10.1073/pnas.1120763109
- Mitchell, D. J. i Cusack, R. (2008). Flexible, Capacity-Limited Activity of Posterior Parietal Cortex in Perceptual as well as Visual Short-Term Memory Tasks. *Cerebral Cortex*, 18(8), 1788–1798. doi: 10.1093/cercor/bhm205
- Morey, C. C. (2018). The case against specialized visual-spatial short-term memory. *Psychological Bulletin*. doi: 10.1037/bul0000155
- Mounts, J. R. (2000). Evidence for suppressive mechanisms in attentional selection: feature singletons produce inhibitory surrounds. *Perception & Psychophysics*, 62(5), 969–983.
- Murray, A. M., Nobre, A. C., Clark, I. A., Cravo, A. M. i Stokes, M. G. (2013). Attention Restores Discrete Items to Visual Short-Term Memory. *Psychological Science*, 24(4), 550–556. doi: 10.1177/0956797612457782
- Myers, N. E., Chekroud, S. R., Stokes, M. G. i Nobre, A. C. (2017). Benefits of Flexible Prioritization in Working Memory Can Arise Without Costs. *Journal of Experimental Psychology: Human Perception and Performance*. doi: 10.1037/xhp0000449
- Myers, N. E., Stokes, M. G., Walther, L. i Nobre, A. C. (2014). Oscillatory Brain State Predicts Variability in Working Memory. *Journal of Neuroscience*, 34(23), 7735–7743. doi: 10.1523/JNEUROSCI.4741-13.2014
- Myers, N. E., Walther, L., Wallis, G., Stokes, M. G. i Nobre, A. C. (2015). Temporal Dynamics of Attention during Encoding versus Maintenance of Working Memory: Complementary Views from Event-related Potentials and Alpha-band Oscillations. *Journal of Cognitive Neuroscience*, 27(3), 492–508. doi: 10.1162/jocn_a_00727
- Nassar, M. R., Helmers, J. C. i Frank, M. J. (2018). Chunking as a rational strategy for lossy data compression in visual working memory. *Psychological Review*, 125(4), 486–511. doi: 10.1037/rev0000101
- Nelissen, N., Stokes, M., Nobre, A. C. i Rushworth, M. F. S. (2013). Frontal and Parietal Cortical Interactions with Distributed Visual Representations during Selective Attention and Action Selection. *Journal of Neuroscience*, 33(42), 16443–16458.
- Nemes, V., Parry, N. R. A., Whitaker, D. i McKeefry, D. J. (2012). The retention and disruption of color information in human short-term visual memory. *Journal of Vision*, 12(1), 26–26.

doi: 10.1167/12.1.26

- Nemes, V., Whitaker, D., Heron, J. i McKeefry, D. (2011). Multiple spatial frequency channels in human visual perceptual memory. *Vision Research*, *51*(23-24), 2331–2339. doi: 10.1016/j.visres.2011.09.003
- Nicholls, A. P., Parmentier, F. B. R., Jones, D. M. i Tremblay, S. (2005). Visual distraction and visuo-spatial memory: A sandwich effect. *Memory*, *13*(3-4), 357–363. doi: 10.1080/09658210344000422
- Nieuwenstein, M. i Wyble, B. (2014). Beyond a mask and against the bottleneck: Retroactive dual-task interference during working memory consolidation of a masked visual target. *Journal of Experimental Psychology: General*, *143*(3), 1409–1427. doi: 10.1037/a0035257
- Nilsson, T. H. i Nelson, T. M. (1981). Delayed monochromatic hue matches indicate characteristics of visual memory. *Journal of Experimental Psychology: Human Perception and Performance*, *7*(1), 141–150. doi: 10.1037/0096-1523.7.1.141
- Nobre, A. C. (2008). Spatial attention can bias search in visual short-term memory. *Frontiers in Human Neuroscience*, *1*. doi: 10.3389/neuro.09.004.2007
- Noonan, M. P., Adamian, N., Pike, A., Printzlau, F., Crittenden, B. M. i Stokes, M. G. (2016). Distinct Mechanisms for Distractor Suppression and Target Facilitation. *Journal of Neuroscience*, *36*(6), 1797–1807. doi: 10.1523/JNEUROSCI.2133-15.2016
- Noorani, I. i Carpenter, R. (2016). The LATER model of reaction time and decision. *Neuroscience & Biobehavioral Reviews*, *64*, 229–251. doi: 10.1016/j.neubiorev.2016.02.018
- Nosofsky, R. M. i Donkin, C. (2016). Qualitative contrast between knowledge-limited mixed-state and variable-resources models of visual change detection. *Journal of Experimental Psychology: Learning, Memory, and Cognition*, *42*(10), 1507–1525. doi: 10.1037/xlm0000268
- Oberauer, K. i Lin, H.-Y. (2017). An interference model of visual working memory. *Psychological Review*, *124*(1), 21–59. doi: 10.1037/rev0000044
- Oostwoud Wijdenes, L., Marshall, L. i Bays, P. M. (2015). Evidence for Optimal Integration of Visual Feature Representations across Saccades. *Journal of Neuroscience*, *35*(28), 10146–10153. doi: 10.1523/JNEUROSCI.1040-15.2015
- Paller, K. A., Kutas, M. i Mayes, A. R. (1987). Neural correlates of encoding in an incidental learning paradigm. *Electroencephalography and Clinical Neurophysiology*, *67*(4), 360–371.
- Palmer, J. (1994). Set-size effects in visual search: The effect of attention is independent of the stimulus for simple tasks. *Vision Research*, *34*(13), 1703–1721. doi: 10.1016/0042-6989(94)90128-7
- Pashler, H. (1988). Familiarity and visual change detection. *Perception & Psychophysics*,

- 44(4), 369–378.
- Pashler, H. (1994). Dual-task interference in simple tasks: data and theory. *Psychological Bulletin*, 116(2), 220–244.
- Pasternak, T., Lui, L. L. i Spinelli, P. M. (2015). Unilateral Prefrontal Lesions Impair Memory-Guided Comparisons of Contralateral Visual Motion. *Journal of Neuroscience*, 35(18), 7095–7105. doi: 10.1523/JNEUROSCI.5265-14.2015
- Pasternak, T. i Zaksas, D. (2003). Stimulus Specificity and Temporal Dynamics of Working Memory for Visual Motion. *Journal of Neurophysiology*, 90(4), 2757–2762. doi: 10.1152/jn.00422.2003
- Pastor-Bernier, A. i Cisek, P. (2011). Neural Correlates of Biased Competition in Premotor Cortex. *Journal of Neuroscience*, 31(19), 7083–7088. doi: 10.1523/JNEUROSCI.5681-10.2011
- Pearson, B., Raskevicius, J., Bays, P. M., Pertzov, Y. i Husain, M. (2014). Working memory retrieval as a decision process. *Journal of Vision*, 14(2), 2–2. doi: 10.1167/14.2.2
- Persuh, M., LaRock, E. i Berger, J. (2018). Working Memory and Consciousness: The Current State of Play. *Frontiers in Human Neuroscience*, 12. doi: 10.3389/fnhum.2018.00078
- Pertzov, Y., Bays, P. M., Joseph, S. i Husain, M. (2013). Rapid forgetting prevented by retrospective attention cues. *Journal of Experimental Psychology: Human Perception and Performance*, 39(5), 1224–1231. doi: 10.1037/a0030947
- Pertzov, Y., Manohar, S. i Husain, M. (2017). Rapid forgetting results from competition over time between items in visual working memory. *Journal of Experimental Psychology: Learning, Memory, and Cognition*, 43(4), 528–536. doi: 10.1037/xlm0000328
- Peters, M. A. K. i Lau, H. (2015). Human observers have optimal introspective access to perceptual processes even for visually masked stimuli. *eLife*, 4. doi: 10.7554/eLife.09651
- Peters, M. A. K., Ro, T. i Lau, H. (2016). Who's afraid of response bias? *Neuroscience of Consciousness*, 2016(1), niw001. doi: 10.1093/nc/niw001
- Polat, U., Sterkin, A. i Yehezkel, O. (2007). Spatio-temporal low-level neural networks account for visual masking. *Advances in Cognitive Psychology*, 3(1), 153–165. doi: 10.2478/v10053-008-0021-4
- Posner, M. I. (1980). Orienting of attention. *The Quarterly Journal of Experimental Psychology*, 32(1), 3–25.
- Postle, B., Druzgal, T. i Desposito, M. (2003). Seeking the Neural Substrates of Visual Working Memory Storage. *Cortex*, 39(4-5), 927–946. doi: 10.1016/S0010-9452(08)70871-2
- Postle, B. R. (2015). The cognitive neuroscience of visual short-term memory. *Current Opinion in Behavioral Sciences*, 1, 40–46. doi: 10.1016/j.cobeha.2014.08.004
- Pouget, A., Dayan, P. i Zemel, R. (2000). Information processing with population codes. *Nature Reviews. Neuroscience*, 1(2), 125–132.

- Pratte, M. S., Park, Y. E., Rademaker, R. L. i Tong, F. (2017). Accounting for stimulus-specific variation in precision reveals a discrete capacity limit in visual working memory. *Journal of Experimental Psychology: Human Perception and Performance*, 43(1), 6–17. doi: 10.1037/xhp0000302
- Prinzmetal, W., Amiri, H., Allen, K. i Edwards, T. (1998). Phenomenology of attention: I. Color, location, orientation, and spatial frequency. *Journal of Experimental Psychology: Human Perception and Performance*, 24(1), 261–282. doi: 10.1037/0096-1523.24.1.261
- Prinzmetal, W., Nwachuku, I., Bodanski, L., Blumenfeld, L. i Shimizu, N. (1997). The Phenomenology of Attention. *Consciousness and Cognition*, 6(2-3), 372–412. doi: 10.1006/ccog.1997.0313
- Rademaker, R. L., Bloem, I. M., De Weerd, P. i Sack, A. T. (2015). The impact of interference on short-term memory for visual orientation. *Journal of Experimental Psychology: Human Perception and Performance*, 41(6), 1650–1665. doi: 10.1037/xhp0000110
- Rademaker, R. L., Chunharas, C. i Serences, J. T. (2018). Simultaneous representation of sensory and mnemonic information in human visual cortex. doi: 10.1101/339200
- Rademaker, R. L., Park, Y. E., Sack, A. T. i Tong, F. (2018). Evidence of gradual loss of precision for simple features and complex objects in visual working memory. *Journal of Experimental Psychology: Human Perception and Performance*. doi: 10.1037/xhp0000491
- Rademaker, R. L., Tredway, C. H. i Tong, F. (2012). Introspective judgments predict the precision and likelihood of successful maintenance of visual working memory. *Journal of Vision*, 12(13), 21–21. doi: 10.1167/12.13.21
- Rademaker, R. L., van de Ven, V. G., Tong, F. i Sack, A. T. (2017). The impact of early visual cortex transcranial magnetic stimulation on visual working memory precision and guess rate. *PLOS ONE*, 12(4), e0175230. doi: 10.1371/journal.pone.0175230
- Rajsic, J., Swan, G., Wilson, D. E. i Pratt, J. (2017). Accessibility limits recall from visual working memory. *Journal of Experimental Psychology: Learning, Memory, and Cognition*, 43(9), 1415–1431. doi: 10.1037/xlm0000387
- Rajsic, J. i Wilson, D. E. (2014). Asymmetrical access to color and location in visual working memory. *Attention, Perception, & Psychophysics*, 76(7), 1902–1913. doi: 10.3758/s13414-014-0723-2
- Ranganath, C. i Blumenfeld, R. S. (2005). Doubts about double dissociations between short- and long-term memory. *Trends in Cognitive Sciences*, 9(8), 374–380. doi: 10.1016/j.tics.2005.06.009
- Reddi, B., Asrress, K. N. i Carpenter, R. (2003). Accuracy, Information, and Response Time in a Saccadic Decision Task. *Journal of Neurophysiology*, 90(5), 3538–3546. doi: 10.1152/jn.00689.2002
- Rerko, L. i Oberauer, K. (2013). Focused, unfocused, and defocused information in working

- memory. *Journal of Experimental Psychology: Learning, Memory, and Cognition*, 39(4), 1075–1096. doi: 10.1037/a0031172
- Rerko, L., Oberauer, K. i Lin, H.-Y. (2014). Spatial transposition gradients in visual working memory. *The Quarterly Journal of Experimental Psychology*, 67(1), 3–15. doi: 10.1080/17470218.2013.789543
- Rerko, L., Souza, A. S. i Oberauer, K. (2014). Retro-cue benefits in working memory without sustained focal attention. *Memory & Cognition*, 42(5), 712–728. doi: 10.3758/s13421-013-0392-8
- Reynolds, J. H. i Chelazzi, L. (2004). Attentional modulation of visual processing. *Annual Review of Neuroscience*, 27(1), 611–647. doi: 10.1146/annurev.neuro.26.041002.131039
- Reynolds, J. H. i Heeger, D. J. (2009). The Normalization Model of Attention. *Neuron*, 61(2), 168–185. doi: 10.1016/j.neuron.2009.01.002
- Rideaux, R. i Edwards, M. (2016). The cost of parallel consolidation into visual working memory. *Journal of Vision*, 16(6), 1. doi: 10.1167/16.6.1
- Riggall, A. C. i Postle, B. R. (2012). The relationship between working memory storage and elevated activity as measured with functional magnetic resonance imaging. *The Journal of Neuroscience: The Official Journal of the Society for Neuroscience*, 32(38), 12990–12998.
- Riley, M. R. i Constantinidis, C. (2016). Role of Prefrontal Persistent Activity in Working Memory. *Frontiers in Systems Neuroscience*, 9. doi: 10.3389/fnsys.2015.00181
- Ritchie, J. B., Kaplan, D. M. i Klein, C. (2017). Decoding the Brain: Neural Representation and the Limits of Multivariate Pattern Analysis in Cognitive Neuroscience. *The British Journal for the Philosophy of Science*. doi: 10.1093/bjps/axx023
- Robert, C., Borella, E., Fagot, D., Lecerf, T. i de Ribaupierre, A. (2009). Working memory and inhibitory control across the life span: Intrusion errors in the Reading Span Test. *Memory & Cognition*, 37(3), 336–345. doi: 10.3758/MC.37.3.336
- Robison, M. K., Miller, A. L. i Unsworth, N. (2018). Individual differences in working memory capacity and filtering. *Journal of Experimental Psychology: Human Perception and Performance*. doi: 10.1037/xhp0000513
- Robitaille, N., Grimault, S. i Jolicœur, P. (2009). Bilateral parietal and contralateral responses during maintenance of unilaterally encoded objects in visual short-term memory: Evidence from magnetoencephalography. *Psychophysiology*, 46(5), 1090–1099. doi: 10.1111/j.1469-8986.2009.00837.x
- Rose, N. S., LaRocque, J. J., Riggall, A. C., Gosseries, O., Starrett, M. J., Meyering, E. E. i Postle, B. R. (2016). Reactivation of latent working memories with transcranial magnetic stimulation. *Science*, 354(6316), 1136–1139. doi: 10.1126/science.aah7011
- Rouder, J. N. i Morey, R. D. (2012). Default Bayes Factors for Model Selection in Regre-

- ssion. *Multivariate Behavioral Research*, 47(6), 877–903. doi: 10.1080/00273171.2012.734737
- Rouder, J. N., Morey, R. D., Cowan, N., Zwilling, C. E., Morey, C. C. i Pratte, M. S. (2008). An assessment of fixed-capacity models of visual working memory. *Proceedings of the National Academy of Sciences*, 105(16), 5975–5979. doi: 10.1073/pnas.0711295105
- Rouder, J. N., Morey, R. D., Speckman, P. L. i Province, J. M. (2012). Default Bayes factors for ANOVA designs. *Journal of Mathematical Psychology*, 56(5), 356–374. doi: 10.1016/j.jmp.2012.08.001
- Rugg, M. D., Johnson, J. D., Park, H. i Uncapher, M. R. (2008). Encoding-retrieval overlap in human episodic memory: A functional neuroimaging perspective. U: *Progress in Brain Research* (Vol. 169, str. 339–352). Elsevier. doi: 10.1016/S0079-6123(07)00021-0
- Sakai, K., Rowe, J. B. i Passingham, R. E. (2002). Active maintenance in prefrontal area 46 creates distractor-resistant memory. *Nature Neuroscience*, 5(5), 479–484. doi: 10.1038/nn846
- Sanger, T. D. (2003). Neural population codes. *Current Opinion in Neurobiology*, 13(2), 238–249.
- Saults, J. S. i Cowan, N. (2007). A central capacity limit to the simultaneous storage of visual and auditory arrays in working memory. *Journal of Experimental Psychology: General*, 136(4), 663–684. doi: 10.1037/0096-3445.136.4.663
- Schmidt, T. (2015). Invisible Stimuli, Implicit Thresholds: Why Invisibility Judgments Cannot be Interpreted in Isolation. *Advances in Cognitive Psychology*, 11(2), 31–41. doi: 10.5709/acp-0169-3
- Schneegans, S. i Bays, P. M. (2016). No fixed item limit in visuospatial working memory. *Cortex*, 83, 181–193. doi: 10.1016/j.cortex.2016.07.021
- Schneegans, S. i Bays, P. M. (2017a). Neural Architecture for Feature Binding in Visual Working Memory. *The Journal of Neuroscience*, 37(14), 3913–3925. doi: 10.1523/JNEUROSCI.3493-16.2017
- Schneegans, S. i Bays, P. M. (2017b). Restoration of fMRI Decodability Does Not Imply Latent Working Memory States. *Journal of Cognitive Neuroscience*, 29(12), 1977–1994. doi: 10.1162/jocn_a_01180
- Schneegans, S. i Bays, P. M. (2018). Drift in Neural Population Activity Causes Working Memory to Deteriorate Over Time. *The Journal of Neuroscience*, 38(21), 4859–4869. doi: 10.1523/JNEUROSCI.3440-17.2018
- Schon, K. (2004). Persistence of Parahippocampal Representation in the Absence of Stimulus Input Enhances Long-Term Encoding: A Functional Magnetic Resonance Imaging Study of Subsequent Memory after a Delayed Match-to-Sample Task. *Journal of Neuroscience*, 24(49), 11088–11097. doi: 10.1523/JNEUROSCI.3807-04.2004

- Schroeder, S. C. Y., Ball, F. i Busch, N. A. (2018). The role of alpha oscillations in distractor inhibition during memory retention. *European Journal of Neuroscience*. doi: 10.1111/ejn.13852
- Schurgin, M. W. (2018). Visual memory, the long and the short of it: A review of visual working memory and long-term memory. *Attention, Perception, & Psychophysics*. doi: 10.3758/s13414-018-1522-y
- Schurgin, M. W., Wixted, J. T. i Brady, T. F. (2018). Psychological Scaling Reveals a Single Parameter Framework For Visual Working Memory. doi: 10.1101/325472
- Schwarzkopf, D. S., Silvanto, J. i Rees, G. (2011). Stochastic Resonance Effects Reveal the Neural Mechanisms of Transcranial Magnetic Stimulation. *Journal of Neuroscience*, 31(9), 3143–3147. doi: 10.1523/JNEUROSCI.4863-10.2011
- Scimeca, J. M., Kiyonaga, A. i D’Esposito, M. (2018). Reaffirming the Sensory Recruitment Account of Working Memory. *Trends in Cognitive Sciences*, 22(3), 190–192. doi: 10.1016/j.tics.2017.12.007
- Scocchia, L., Cicchini, G. M. i Triesch, J. (2013). What’s “up”? Working memory contents can bias orientation processing. *Vision Research*, 78, 46–55. doi: 10.1016/j.visres.2012.12.003
- Serences, J. T. (2016). Neural mechanisms of information storage in visual short-term memory. *Vision Research*, 128, 53–67. doi: 10.1016/j.visres.2016.09.010
- Serences, J. T., Ester, E. F., Vogel, E. K. i Awh, E. (2009). Stimulus-Specific Delay Activity in Human Primary Visual Cortex. *Psychological Science*, 20(2), 207–214. doi: 10.1111/j.1467-9280.2009.02276.x
- Sergent, C. i Dehaene, S. (2004). Is Consciousness a Gradual Phenomenon?: Evidence for an All-or-None Bifurcation During the Attentional Blink. *Psychological Science*, 15(11), 720–728. doi: 10.1111/j.0956-7976.2004.00748.x
- Seung, H. S. i Sompolinsky, H. (1993). Simple models for reading neuronal population codes. *Proceedings of the National Academy of Sciences*, 90(22), 10749–10753. doi: 10.1073/pnas.90.22.10749
- Shannon, C. E. (1948). A Mathematical Theory of Communication. *Bell System Technical Journal*, 27(3), 379–423. doi: 10.1002/j.1538-7305.1948.tb01338.x
- Shepherdson, P., Oberauer, K. i Souza, A. S. (2017). Working Memory Load and the Retro-Cue Effect: A Diffusion Model Account. *Journal of Experimental Psychology: Human Perception and Performance*. doi: 10.1037/xhp0000448
- Shibuya, H. i Bundesen, C. (1988). Visual selection from multielement displays: Measuring and modeling effects of exposure duration. *Journal of Experimental Psychology: Human Perception and Performance*, 14(4), 591–600. doi: 10.1037/0096-1523.14.4.591
- Shimi, A., Nobre, A. C., Astle, D. i Scerif, G. (2014). Orienting Attention Within Visual Short-

- Term Memory: Development and Mechanisms. *Child Development*, 85(2), 578–592. doi: 10.1111/cdev.12150
- Shipstead, Z., Lindsey, D. R., Marshall, R. L. i Engle, R. W. (2014). The mechanisms of working memory capacity: Primary memory, secondary memory, and attention control. *Journal of Memory and Language*, 72, 116–141.
- Silvanto, J. i Soto, D. (2012). Causal evidence for subliminal percept-to-memory interference in early visual cortex. *NeuroImage*, 59(1), 840–845. doi: 10.1016/j.neuroimage.2011.07.062
- Sims, C. R., Jacobs, R. A. i Knill, D. C. (2012). An Ideal Observer Analysis of Visual Working Memory. *Psychological Review*, No Pagination Specified.
- Smith, E. E., Jonides, J., Koeppel, R. A., Awh, E., Schumacher, E. H. i Minoshima, S. (1995). Spatial versus Object Working Memory: PET Investigations. *Journal of Cognitive Neuroscience*, 7(3), 337–356. doi: 10.1162/jocn.1995.7.3.337
- Smyth, M. M., Hay, D. C., Hitch, G. J. i Horton, N. J. (2005). Serial Position Memory in the Visual—Spatial Domain: Reconstructing Sequences of Unfamiliar Faces. *The Quarterly Journal of Experimental Psychology Section A*, 58(5), 909–930. doi: 10.1080/02724980443000412
- Sneve, M. H., Alnæs, D., Endestad, T., Greenlee, M. W. i Magnussen, S. (2011). Modulation of Activity in Human Visual Area V1 during Memory Masking. *PLoS ONE*, 6(4), e18651. doi: 10.1371/journal.pone.0018651
- Sneve, M. H., Sreenivasan, K. K., Alnæs, D., Endestad, T. i Magnussen, S. (2015). Short-term retention of visual information: Evidence in support of feature-based attention as an underlying mechanism. *Neuropsychologia*, 66, 1–9. doi: 10.1016/j.neuropsychologia.2014.11.004
- Snowden, R. J. i Hammett, S. T. (1998). The effects of surround contrast on contrast thresholds, perceived contrast and contrast discrimination. *Vision Research*, 38(13), 1935–1945. doi: 10.1016/S0042-6989(97)00379-9
- Soto, D., Hodsoll, J., Rotshtein, P. i Humphreys, G. W. (2008). Automatic guidance of attention from working memory. *Trends in Cognitive Sciences*, 12(9), 342–348.
- Soto, D., Mäntylä, T. i Silvanto, J. (2011). Working memory without consciousness. *Current Biology*, 21(22), R912–R913. doi: 10.1016/j.cub.2011.09.049
- Souza, A. S. i Oberauer, K. (2016). In search of the focus of attention in working memory: 13 years of the retro-cue effect. *Attention, Perception, & Psychophysics*, 78(7), 1839–1860. doi: 10.3758/s13414-016-1108-5
- Souza, A. S., Rerko, L., Lin, H.-Y. i Oberauer, K. (2014). Focused attention improves working memory: implications for flexible-resource and discrete-capacity models. *Attention, Perception, & Psychophysics*, 76(7), 2080–2102. doi: 10.3758/s13414-014-0687-2

- Souza, A. S., Rerko, L. i Oberauer, K. (2014). Unloading and reloading working memory: Attending to one item frees capacity. *Journal of Experimental Psychology: Human Perception and Performance*, 40(3), 1237–1256. doi: 10.1037/a0036331
- Souza, A. S., Rerko, L. i Oberauer, K. (2015). Refreshing memory traces: thinking of an item improves retrieval from visual working memory. *Annals of the New York Academy of Sciences*, 1339(1), 20–31. doi: 10.1111/nyas.12603
- Souza, A. S., Rerko, L. i Oberauer, K. (2016). Getting More From Visual Working Memory: Retro-Cues Enhance Retrieval and Protect From Visual Interference. *Journal of Experimental Psychology: Human Perception and Performance*. doi: 10.1037/xhp0000192
- Sperling, G. (1960). The information available in brief visual presentations. *Psychological Monographs: General and Applied*, 74(11), 1–29. doi: 10.1037/h0093759
- Sprague, T. C., Ester, E. i Serences, J. (2014). Reconstructions of Information in Visual Spatial Working Memory Degrade with Memory Load. *Current Biology*, 24(18), 2174–2180. doi: 10.1016/j.cub.2014.07.066
- Sprague, T. C., Ester, E. F. i Serences, J. T. (2016). Restoring Latent Visual Working Memory Representations in Human Cortex. *Neuron*, 91(3), 694–707. doi: 10.1016/j.neuron.2016.07.006
- Sprague, T. C., Ma, W. J. i Curtis, C. (2018). Temporal dynamics of visual working memory representations across human cortex. *Journal of Vision*, 18(10), 113. doi: 10.1167/18.10.113
- Sreenivasan, K. K., Curtis, C. E. i D’Esposito, M. (2014). Revisiting the role of persistent neural activity during working memory. *Trends in Cognitive Sciences*, 18(2), 82–89. doi: 10.1016/j.tics.2013.12.001
- Sreenivasan, K. K. i Jha, A. P. (2007). Selective Attention Supports Working Memory Maintenance by Modulating Perceptual Processing of Distractors. *Journal of Cognitive Neuroscience*, 19(1), 32–41. doi: 10.1162/jocn.2007.19.1.32
- Stein, T., Kaiser, D. i Hesselmann, G. (2016). Can working memory be non-conscious? *Neuroscience of Consciousness*, 2016(1), niv011. doi: 10.1093/nc/niv011
- Stewart, E. E. i Schütz, A. C. (2018). Attention modulates trans-saccadic integration. *Vision Research*, 142, 1–10. doi: 10.1016/j.visres.2017.11.006
- Stokes, D., Matthen, M. i Biggs, S. (Ur.). (2014). *Perception and Its Modalities*. Oxford University Press. doi: 10.1093/acprof:oso/9780199832798.001.0001
- Stokes, M. G. (2015). ‘Activity-silent’ working memory in prefrontal cortex: a dynamic coding framework. *Trends in Cognitive Sciences*, 19(7), 394–405. doi: 10.1016/j.tics.2015.05.004
- Störmer, V. i Alvarez, G. (2014). Feature-Based Attention Elicits Surround Suppression in Feature Space. *Current Biology*, 24(17), 1985–1988. doi: 10.1016/j.cub.2014.07.030

- Suchow, J. W., Fougny, D. i Alvarez, G. A. (2017). Looking inward and back: Real-time monitoring of visual working memories. *Journal of Experimental Psychology: Learning, Memory, and Cognition*, *43*(4), 660–668. doi: 10.1037/xlm0000320
- Sun, J. Z., Wang, G. I., Goyal, V. K. i Varshney, L. R. (2012). A framework for Bayesian optimality of psychophysical laws. *Journal of Mathematical Psychology*, *56*(6), 495–501. doi: 10.1016/j.jmp.2012.08.002
- Swets, J. A. (1986a). Form of empirical ROCs in discrimination and diagnostic tasks: implications for theory and measurement of performance. *Psychological Bulletin*, *99*(2), 181–198.
- Swets, J. A. (1986b). Indices of discrimination or diagnostic accuracy: their ROCs and implied models. *Psychological Bulletin*, *99*(1), 100–117.
- Taylor, R. i Bays, P. M. (2018). Efficient coding in visual working memory accounts for stimulus-specific variations in recall. *The Journal of Neuroscience*, 1018–18. doi: 10.1523/JNEUROSCI.1018-18.2018
- Thibault, L., van den Berg, R., Cavanagh, P. i Sergent, C. (2016). Retrospective Attention Gates Discrete Conscious Access to Past Sensory Stimuli. *PLOS ONE*, *11*(2), e0148504. doi: 10.1371/journal.pone.0148504
- Todd, J. J., Han, S. W., Harrison, S. i Marois, R. (2011). The neural correlates of visual working memory encoding: A time-resolved fMRI study. *Neuropsychologia*, *49*(6), 1527–1536. doi: 10.1016/j.neuropsychologia.2011.01.040
- Todd, J. J. i Marois, R. (2004). Capacity limit of visual short-term memory in human posterior parietal cortex. *Nature*, *428*(6984), 751–754. doi: 10.1038/nature02466
- Tomić, I. i Bays, P. M. (2018). Internal but not external noise frees working memory resources. *PLOS Computational Biology*, *14*(10), e1006488. doi: 10.1371/journal.pcbi.1006488
- Tresch, M. C., Sinnamon, H. M. i Seamon, J. G. (1993). Double dissociation of spatial and object visual memory: evidence from selective interference in intact human subjects. *Neuropsychologia*, *31*(3), 211–219.
- Trübtschek, D., Marti, S., Ojeda, A., King, J.-R., Mi, Y., Tsodyks, M. i Dehaene, S. (2017). A theory of working memory without consciousness or sustained activity. *eLife*, *6*. doi: 10.7554/eLife.23871
- Tsubomi, H., Fukuda, K., Watanabe, K. i Vogel, E. K. (2013). Neural Limits to Representing Objects Still within View. *Journal of Neuroscience*, *33*(19), 8257–8263. doi: 10.1523/JNEUROSCI.5348-12.2013
- Ueno, T., Allen, R. J., Baddeley, A. D., Hitch, G. J. i Saito, S. (2011). Disruption of visual feature binding in working memory. *Memory & Cognition*, *39*(1), 12–23. doi: 10.3758/s13421-010-0013-8
- Ueno, T., Mate, J., Allen, R. J., Hitch, G. J. i Baddeley, A. D. (2011). What goes through

- the gate? Exploring interference with visual feature binding. *Neuropsychologia*, 49(6), 1597–1604. doi: 10.1016/j.neuropsychologia.2010.11.030
- van den Berg, R., Awh, E. i Ma, W. J. (2014). Factorial comparison of working memory models. *Psychological Review*, 121(1), 124–149. doi: 10.1037/a0035234
- van den Berg, R. i Ma, W. J. (2018). A resource-rational theory of set size effects in human visual working memory. *eLife*, 7. doi: 10.7554/eLife.34963
- van den Berg, R., Shin, H., Chou, W.-C., George, R. i Ma, W. J. (2012). Variability in encoding precision accounts for visual short-term memory limitations. *Proceedings of the National Academy of Sciences*, 109(22), 8780–8785. doi: 10.1073/pnas.1117465109
- van den Berg, R., Yoo, A. H. i Ma, W. J. (2017). Fechner’s law in metacognition: A quantitative model of visual working memory confidence. *Psychological Review*, 124(2), 197–214. doi: 10.1037/rev0000060
- Vandenbroucke, A. R. E., Sligte, I. G., de Vries, J. G., Cohen, M. X. i Lamme, V. A. F. (2015). Neural Correlates of Visual Short-term Memory Dissociate between Fragile and Working Memory Representations. *Journal of Cognitive Neuroscience*, 27(12), 2477–2490. doi: 10.1162/jocn_a_00870
- Van der Stigchel, S., Merten, H., Meeter, M. i Theeuwes, J. (2007). The effects of a task-irrelevant visual event on spatial working memory. *Psychonomic Bulletin & Review*, 14(6), 1066–1071.
- van de Ven, V., Jacobs, C. i Sack, A. T. (2012). Topographic Contribution of Early Visual Cortex to Short-Term Memory Consolidation: A Transcranial Magnetic Stimulation Study. *Journal of Neuroscience*, 32(1), 4–11. doi: 10.1523/JNEUROSCI.3261-11.2012
- van Dijk, H., van der Werf, J., Mazaheri, A., Medendorp, W. P. i Jensen, O. (2010). Modulations in oscillatory activity with amplitude asymmetry can produce cognitively relevant event-related responses. *Proceedings of the National Academy of Sciences*, 107(2), 900–905. doi: 10.1073/pnas.0908821107
- van Ede, F., Chekroud, S. R., Stokes, M. G. i Nobre, A. C. (2018). Decoding the influence of anticipatory states on visual perception in the presence of temporal distractors. *Nature Communications*, 9(1). doi: 10.1038/s41467-018-03960-z
- van Ede, F., Quinn, A. J., Woolrich, M. W. i Nobre, A. C. (2018). Neural Oscillations: Sustained Rhythms or Transient Burst-Events? *Trends in Neurosciences*, 41(7), 415–417. doi: 10.1016/j.tins.2018.04.004
- van Lamsweerde, A. E. i Johnson, J. S. (2017). Assessing the Effect of Early Visual Cortex Transcranial Magnetic Stimulation on Working Memory Consolidation. *Journal of Cognitive Neuroscience*, 29(7), 1226–1238. doi: 10.1162/jocn_a_01113
- van Loon, A. M., Olmos-Solis, K., Fahrenfort, J. J. i Olivers, C. N. (2018). Current and future goals are represented in opposite patterns in object-selective cortex. *eLife*, 7. doi:

10.7554/eLife.38677

- van Moorselaar, D., Gunseli, E., Theeuwes, J. i Olivers, C. (2015). The time course of protecting a visual memory representation from perceptual interference. *Frontiers in Human Neuroscience*, 8. doi: 10.3389/fnhum.2014.01053
- van Moorselaar, D., Olivers, C. N. L., Theeuwes, J., Lamme, V. A. F. i Sligte, I. G. (2015). Forgotten but not gone: Retro-cue costs and benefits in a double-cueing paradigm suggest multiple states in visual short-term memory. *Journal of Experimental Psychology: Learning, Memory, and Cognition*, 41(6), 1755–1763. doi: 10.1037/xlm0000124
- Vergauwe, E., Barrouillet, P. i Camos, V. (2009). Visual and spatial working memory are not that dissociated after all: A time-based resource-sharing account. *Journal of Experimental Psychology: Learning, Memory, and Cognition*, 35(4), 1012–1028. doi: 10.1037/a0015859
- Vergauwe, E., Langerock, N. i Barrouillet, P. (2014). Maintaining information in visual working memory: Memory for bindings and memory for features are equally disrupted by increased attentional demands. *Canadian Journal of Experimental Psychology/Revue canadienne de psychologie expérimentale*, 68(3), 158–162. doi: 10.1037/cep0000025
- Vincent, A. i Regan, D. (1995). Parallel Independent Encoding of Orientation, Spatial Frequency, and Contrast. *Perception*, 24(5), 491–499. doi: 10.1068/p240491
- Vissers, M. E., Gulbinaite, R., van den Bos, T. i Slagter, H. A. (2017). Protecting visual short-term memory during maintenance: Attentional modulation of target and distractor representations. *Scientific Reports*, 7(1). doi: 10.1038/s41598-017-03995-0
- Vogel, E. K. i Machizawa, M. G. (2004). Neural activity predicts individual differences in visual working memory capacity. *Nature*, 428(6984), 748–751. doi: 10.1038/nature02447
- Vogel, E. K., McCollough, A. W. i Machizawa, M. G. (2005). Neural measures reveal individual differences in controlling access to working memory. *Nature*, 438(7067), 500–503. doi: 10.1038/nature04171
- Vogel, E. K., Woodman, G. F. i Luck, S. J. (2006). The time course of consolidation in visual working memory. *Journal of Experimental Psychology: Human Perception and Performance*, 32(6), 1436–1451. doi: 10.1037/0096-1523.32.6.1436
- Vuontela, V., Rämä, P., Raninen, A., Aronen, H. J. i Carlson, S. (1999). Selective interference reveals dissociation between memory for location and colour. *Neuroreport*, 10(11), 2235–2240.
- Wagenmakers, E.-J., Lee, M., Lodewyckx, T. i Iverson, G. J. (2008). Bayesian Versus Frequentist Inference. U: H. Hoijtink, I. Klugkist i P. A. Boelen (Ur.), *Bayesian Evaluation of Informative Hypotheses* (str. 181–207). New York, NY: Springer New York. doi: 10.1007/978-0-387-09612-4_9
- Wallis, G., Stokes, M., Cousijn, H., Woolrich, M. i Nobre, A. C. (2015). Frontoparietal and

- Cingulo-opercular Networks Play Dissociable Roles in Control of Working Memory. *Journal of Cognitive Neuroscience*, 27(10), 2019–2034. doi: 10.1162/jocn_a_00838
- Wang, B., Theeuwes, J. i Olivers, C. N. L. (2018). When shorter delays lead to worse memories: Task disruption makes visual working memory temporarily vulnerable to test interference. *Journal of Experimental Psychology: Learning, Memory, and Cognition*, 44(5), 722–733. doi: 10.1037/xlm0000468
- Wei, X.-X. i Stocker, A. A. (2015). A Bayesian observer model constrained by efficient coding can explain 'anti-Bayesian' percepts. *Nature Neuroscience*, 18(10), 1509–1517. doi: 10.1038/nn.4105
- Wei, Z., Wang, X.-J. i Wang, D.-H. (2012). From Distributed Resources to Limited Slots in Multiple-Item Working Memory: A Spiking Network Model with Normalization. *Journal of Neuroscience*, 32(33), 11228–11240. doi: 10.1523/JNEUROSCI.0735-12.2012
- Werkle-Bergner, M., Müller, V., Li, S.-C. i Lindenberger, U. (2006). Cortical EEG correlates of successful memory encoding: Implications for lifespan comparisons. *Neuroscience & Biobehavioral Reviews*, 30(6), 839–854. doi: 10.1016/j.neubiorev.2006.06.009
- Wildegger, T., Humphreys, G. i Nobre, A. C. (2016). Retrospective Attention Interacts with Stimulus Strength to Shape Working Memory Performance. *PLOS ONE*, 11(10), e0164174. doi: 10.1371/journal.pone.0164174
- Wilken, P. i Ma, W. J. (2004). A detection theory account of change detection. *Journal of Vision*, 4(12), 11–11. doi: 10.1167/4.12.11
- Williams, M., Hong, S. W., Kang, M.-S., Carlisle, N. B. i Woodman, G. F. (2013). The benefit of forgetting. *Psychonomic Bulletin & Review*, 20(2), 348–355. doi: 10.3758/s13423-012-0354-3
- Wolff, M. J., Jochim, J., Akyürek, E. G. i Stokes, M. G. (2017). Dynamic hidden states underlying working-memory-guided behavior. *Nature Neuroscience*, 20(6), 864–871. doi: 10.1038/nn.4546
- Xing, Y., Ledgeway, T., McGraw, P. V. i Schluppeck, D. (2013). Decoding Working Memory of Stimulus Contrast in Early Visual Cortex. *Journal of Neuroscience*, 33(25), 10301–10311. doi: 10.1523/JNEUROSCI.3754-12.2013
- Xu, Y. (2017). Reevaluating the Sensory Account of Visual Working Memory Storage. *Trends in Cognitive Sciences*. doi: 10.1016/j.tics.2017.06.013
- Xu, Y. (2018). Sensory Cortex Is Nonessential in Working Memory Storage. *Trends in Cognitive Sciences*, 22(3), 192–193. doi: 10.1016/j.tics.2017.12.008
- Xu, Y. i Chun, M. M. (2006). Dissociable neural mechanisms supporting visual short-term memory for objects. *Nature*, 440(7080), 91–95. doi: 10.1038/nature04262
- Xu, Y. i Jeong, S. K. (2015). The Contribution of Human Superior Intraparietal Sulcus to Visual Short-Term Memory and Perception. U: *Mechanisms of Sensory Working Memory* (str.

- 33–42). Elsevier. doi: 10.1016/B978-0-12-801371-7.00004-1
- Yatziv, T. i Kessler, Y. (2018). A two-level hierarchical framework of visual short-term memory. *Journal of Vision*, 18(9), 2. doi: 10.1167/18.9.2
- Yeh, Y.-Y., Yang, C.-T. i Chiu, Y.-C. (2005). Binding or prioritization: The role of selective attention in visual short-term memory. *Visual Cognition*, 12(5), 759–799. doi: 10.1080/13506280444000490
- Yoo, A. H., Klyszejko, Z., Curtis, C. E. i Ma, W. J. (2018). Strategic allocation of working memory resource. doi: 10.1101/329870
- Yoon, J. H., Curtis, C. E. i D’Esposito, M. (2006). Differential effects of distraction during working memory on delay-period activity in the prefrontal cortex and the visual association cortex. *NeuroImage*, 29(4), 1117–1126. doi: 10.1016/j.neuroimage.2005.08.024
- Yu, Q. i Shim, W. M. (2017). Occipital, parietal, and frontal cortices selectively maintain task-relevant features of multi-feature objects in visual working memory. *NeuroImage*, 157, 97–107. doi: 10.1016/j.neuroimage.2017.05.055
- Zeki, S., Watson, J., Lueck, R.-C., Friston, K., Kennard, C. i Frackowiak, R. (1991). A direct demonstration of functional specialization in human visual cortex. *The Journal of Neuroscience*, 11(3), 641–649.
- Zemel, R. S., Dayan, P. i Pouget, A. (1998). Probabilistic interpretation of population codes. *Neural Computation*, 10(2), 403–430.
- Zhang, W. i Luck, S. J. (2008). Discrete fixed-resolution representations in visual working memory. *Nature*, 453(7192), 233–235. doi: 10.1038/nature06860
- Zhang, W. i Luck, S. J. (2011). The Number and Quality of Representations in Working Memory. *Psychological Science*, 22(11), 1434–1441. doi: 10.1177/0956797611417006
- Zokaei, N., Gorgoraptis, N., Bahrami, B., Bays, P. M. i Husain, M. (2011). Precision of working memory for visual motion sequences and transparent motion surfaces. *Journal of Vision*, 11(14), 2–2. doi: 10.1167/11.14.2
- Zokaei, N., Manohar, S., Husain, M. i Feredoes, E. (2014). Causal Evidence for a Privileged Working Memory State in Early Visual Cortex. *Journal of Neuroscience*, 34(1), 158–162. doi: 10.1523/JNEUROSCI.2899-13.2014
- Zokaei, N., Ning, S., Manohar, S., Feredoes, E. i Husain, M. (2014). Flexibility of representational states in working memory. *Frontiers in Human Neuroscience*, 8. doi: 10.3389/fnhum.2014.00853

9 Životopis

Ivan Tomić rođen je 1. rujna 1988. godine u Zagrebu. Osnovnu i srednju školu završio je u Jastrebarskom. U akademskoj godini 2008./2009. upisao je preddiplomski studij psihologije na Odsjeku za psihologiju Filozofskog fakulteta u Zagrebu gdje je diplomirao 2014. godine te dobio nagradu Odsjeka za psihologiju i Hrvatskog psihološkog društva za izvrstan diplomski rad. Tijekom studija bio je demonstrator na nekoliko kolegija na katedrama za opću i eksperimentalnu psihologiju. Kao student od 2013. do 2014. zaposlen je na projektu *Operationalizing Psychosocial Support in Crisis* pod vodstvom prof.dr.sc. Deana Ajdukovića. Od 2014. godine zaposlen je kao asistent na Katedri za eksperimentalnu psihologiju Odsjeka za psihologiju Filozofskog fakulteta u Zagrebu gdje sudjeluje u izvedbi kolegija *Statistika u psihologiji 1*, *Statistika u psihologiji 2*, *Psihologijski praktikum 1* i *Psihologijski praktikum 2*. Iste godine upisao je poslijediplomski doktorski studij pod mentorstvom prof.dr.sc Dragutina Ivaneca. Od 2017. godine suradnik je na projektu *E-rudito - napredni online obrazovni sustav* pod vodstvom prof.dr.sc Dragutina Ivaneca. Do sada je objavio pet radova i pet poglavlja u knjigama, te je sudjelovao na većem broju međunarodnih i domaćih konferencija, radionica i ljetnih škola.

10 Popis objavljenih radova

Znanstveni radovi:

Tomić, I. (2017). Vidno radno pamćenje. *Psihologijske Teme*, 26(3), 601–625.

Tomić, I., Burić, J., & Štulhofer, A. (2017). Associations Between Croatian Adolescents' Use of Sexually Explicit Material and Sexual Behavior: Does Parental Monitoring Play a Role? *Archives of Sexual Behavior*, 47(6), 1881–1893. doi: 10.1007/s10508-017-1097-z

Tomić, I., Tonković, M., & Ivanec, D. (2017). Effects of Psychological Distance and Need for Cognitive Closure on Impression Formation. *The Journal of General Psychology*, 144(1), 1–15. doi: 10.1080/00221309.2016.1258385

Tomić, I., & Bays, P. M. (2018). Internal but not external noise frees working memory resources. *PLOS Computational Biology*, 14(10), e1006488. doi: 10.1371/journal.pcbi.1006488

Koletić, G., Štulhofer, A., Tomić, I., & Knežević Ćuća, J. (2019). Associations between Croatian Adolescents' Use of Sexually Explicit Material and Risky Sexual Behavior: A Latent Growth Curve Modeling Approach. *International Journal of Sexual Health*, 1–15. doi: 10.1080/19317611.2019.1567640

Poglavlja u knjigama:

Ivanec, D., & Tomić, I. (2015). Ako piješ ne vozi: Djeluju li male količine alkohola na psihomotorno ponašanje i kako to ispitati? In M. Tonković Grabovac, U. Mikac, & T. Vukasović Hlupić (Eds.), *PsihoFESTologija - Ovo nije samo još jedna knjiga iz popularne psihologije* (pp. 162–166). Zagreb: FF Press.

Ljubotina, D., & Tomić, I. (2015). Analiza odnosa razvijenosti konstrukta i vremena rada u zadatku i testu. In D. Ljubotina, N. Pavlin-Bernardić, & S. Salkičević (Eds.), *Metodološki aspekti računalne primjene testova* (pp. 107–132). Zagreb: FF Press.

Tomić, I., Korman, M., Ružojčić, M., Pehar, L., Štulić, J., Serhatlić, A., ... Lukšić, M. (2015). Faktori povezani s vremenom rada u testu. In D. Ljubotina, N. Pavlin-Bernardić, & S. Salkičević (Eds.), *Metodološki aspekti računalne primjene testova* (pp. 133–152). Zagreb: FF.

Tomić, I., Serhatlić, A., Čepulić, D. B., Ružojčić, M., Pehar, L., & Vargek, P. (2015). Povezanost brzine rada u računalnom testu i osobina ličnosti. In D. Ljubotina, N. Pavlin-Bernardić, & S. Salkičević (Eds.), *Metodološki aspekti računalne primjene testova* (pp. 69–76). Zagreb: FF Press.

Tonković, M., & Tomić, I. (2015). Zašto veliki na slici postaju mali? Iluzije pri percepciji veličine. In M. Tonković Grabovac, U. Mikac, & T. Vukasović Hlupić (Eds.), *PsihoFESTologija - Ovo nije samo još jedna knjiga iz popularne psihologije* (pp. 20–24). Zagreb: FF Press.