


Metodens betydelse för kartläggning av värmesårbarhet

en jämförelse mellan PCA och additiva index i en urban miljö



Oskar Bork

2026

Miljö- och geovetenskapliga institutionen

Lunds Universitet

Sölvegatan 12

223 62 Lund



Oskar Bork (2026). Metodens betydelse för kartläggning av värmesårbarhet, en jämförelse mellan PCA och additiva index i en urban miljö

Kandidatuppsats, 15 hp i Naturgeografi och Ekosystemanalys

Miljö- och geovetenskapliga institutionen, Lunds Universitet

Nivå: Bachelor of Science

Kursperiod: Mars 2026 till juni 2026

Ansvarsfriskrivning

Detta dokument beskriver det arbete som utförts inom ett studieprogram vid Lunds Universitet. Alla synpunkter och åsikter som uttrycks i denna är den ansvarige författarens, och inte nödvändigtvis institutionens.

Metodens betydelse för kartläggning av värmesårbarhet, en jämförelse mellan PCA och additiva index i en urban miljö

Oskar Bork

Kandidatuppsats, 15 högskolepoäng, i Naturgeografi och Ekosystemanalys

Handledare:

Karin Hall

Miljö- och geovetenskapliga institutionen,

Lunds Universitet

Examinator:

Per-Ola Olsson

Miljö- och geovetenskapliga institutionen,

Lunds Universitet

Förord

Våren 2026 fick jag chansen att arbeta som studentmedarbetare på Miljöförvaltningen i Malmö stad med att uppdatera och vidareutveckla ett tidigare framtaget värmesårbarhetsindex – ett arbete som på många sätt ledde till uppsatsen framför dig. Arbetet resulterade i det värmesårbarhetsindex som är visualiserat på omslaget och jag vill rikta ett stort tack till min handledare på Miljöförvaltning, Emanuel Toft, som guidade mig skickligt genom den organisatoriska komplexiteten som det kan innebära att arbeta på kommun. Att samtidigt skriva en kandidatuppsats inom ämnet var en utmaning som gjordes möjligt av min handledare vid Lunds universitet, Karin Hall – tusen tack för ditt engagemang och vägledning.

Ett stort tack till kollegorna på Miljöförvaltningen i Malmö som fick mig att känna mig mycket välkommen trots att jag bara kunde stanna kort. Tack till Mathilda Englund på Stockholm Environment Institute och Ludwig Wahlund Sonesson på Miljöförvaltningen som arbetat med det tidigare sårbarhetsindexet och som gav värdefulla råd i mitt arbete, samt Rebecka Bergh som var min föregångare som studentmedarbetare för detta projekt. Tack till mina klasskamrater som jag fått nöjet att spenderat de senaste tre åren med, och som jag tillsammans med lärt mig se på världen med en geografisk blick.

Slutligen, tack till mina nära och kära – vännerna i Malmö och familjen i Danmark. Tack Noah för att du kommit med sötsaker och påmint mig om att ta pauser. Tack Louise för att du placerat ord som ”stadstypologi” i min hjärna och gett mig perspektiv på vad som är viktigt.

Oskar Bork, maj 2026

Sammanfattning och abstract

Svenska

Värmeböljor förväntas bli vanligare och mer intensiva till följd av klimatförändringar vilket ökar behovet av geografiska analyser av värmesårbarhet i urbana miljöer som är särskilt värmeutsatta. Denna studie undersöker hur olika metoder för konstruktion av värmesårbarhetsindex påverkar identifieringen av sårbara områden i Malmö. Två etablerade metoder jämförs: ett additivt, oviktat index och ett index baserat på Principal Component Analysis (PCA). Båda indexen konstrueras utifrån åtta sociala indikatorer kopplade till värmesårbarhet på DeSO-nivå (Malmö 209 demografiska statistikområden).

Resultaten visar att metoderna identifierar liknande övergripande geografiska mönster, med relativt hög korrelation mellan indexen. Samtidigt framträder tydliga skillnader i hur sårbarheten fördelas mellan centrala och yttre delar av Malmö. Det additiva indexet ger generellt högre och mer koncentrerade sårbarhetsvärden i centrala områden där flera indikatorer samvarierar, medan PCA-metoden ger ett mer differentierat resultat genom att reducera samvarierande indikatorer till underliggande komponenter. PCA identifierar separata dimensioner av sårbarhet kopplade till socioekonomi, hushållsstruktur och sårbara åldersgrupper.

Studien visar att metodvalet har betydelse för både rangordningen av områden och vilka aspekter av sårbarhet som betonas i slutindexet. Resultaten bidrar till diskussionen om metodologiska val inom forskning om klimatrelaterad sårbarhet genom att visa att olika indexmetoder kan ge delvis olika underlag och analysdjup för klimatanpassningsarbete. Studien identifierar för- och nackdelar med båda metoder och föreslår att de kan lämpa sig bättre inom olika sammanhang, som exempelvis djupgående analys inom akademi (PCA) eller återkommande, praktisk genomförbar analys inom kommunal verksamhet (additivt index).

English

Heatwaves are expected to become more frequent and intense because of climate change, increasing the need for geographical analyses of heat vulnerability, particularly in heat-exposed urban environments. This study examines how different methods for constructing heat vulnerability indices affect the identification of vulnerable areas in Malmö. Two established methods are compared: an additive, unweighted index and an index based on Principal Component Analysis (PCA). Both indices are constructed using eight social indicators of heat vulnerability at the DeSO level (209 census tracts within Malmö).

The results show that the methods identify similar overall geographical patterns, with a relatively high correlation between the indices. However, clear differences emerge in how vulnerability is distributed between central and outer parts of Malmö. The additive index generally yields higher and more concentrated values in central areas where several indicators co-vary, while the PCA method produces a more differentiated result by reducing co-varying indicators into underlying components. PCA identifies separate dimensions of vulnerability related to socioeconomic status, household structure, and vulnerable age groups.

The study shows that the choice of method affects both the ranking of areas as well as which aspects of vulnerability are emphasized in the final index. The results contribute to the discussion of methodological choices in climate-related vulnerability research by demonstrating that different index methods can provide partly different outcomes and levels of analysis for climate adaptation work. The study identifies strengths and weaknesses for both methods and suggests that they might be better suited to different contexts, such as in-depth academic analysis (PCA) or repeated and practical analysis in municipal work (additive index).

Innehåll

Förord	4
Sammanfattning och abstract	5
1. Introduktion	7
1.1 Syfte och frågeställningar	8
2. Metod	9
2.1 Datakällor	9
2.2 Demografiska statistikområden	10
2.3 Konstruktion av index	10
2.3.1 Korrigering för skeva fördelningar	11
2.3.2 Riktning och normalisering	11
2.3.3 Aggregering av additivt index	11
2.3.4 Sårbarhetsindex med PCA	12
3. Resultat	15
3.1 Resultat för PCA-metod	15
3.2 Resultat för additiv metod	17
3.3 Skillnader mellan PCA och additivt index	18
4. Diskussion	22
4.1 Skillnader mellan additiv metod och PCA	22
4.2 Tolkning av PCA-komponenterna och Malmös geografiska mönster	23
4.3 Metodologiska implikationer – för och nackdelar	24
4.4 Begränsningar och framtida forskning	25
5. Sammanfattning	27
Referenser	28

1. Introduktion

Sverige står inför omfattande utmaningar med att anpassa städer i takt med att nya vädermönster etablerar sig och extrema väderhändelser ökar på grund av klimatförändringarna. I Sverige finns sedan tidigare erfarenhet av att hantera risker kopplade till exempelvis skyfall och översvämningar, men värmeböljor utgör en delvis ny typ av utmaning för våra samhällen vars byggda miljö ofta är dåligt anpassad för långvarig värme (Regeringens skrivelse 2023/24:97). Dessutom kan människor i tempererade klimat vara extra sårbara för värme till följd av stora temperaturskillnader mellan säsongerna och låg grad av acklimatisering när värmen väl kommer (Rinner m.fl., 2010). I regeringens nationella strategi för klimatanpassning pekas värmeböljor ut som en redan idag betydande klimatrisk vars negativa konsekvenser förväntas öka i framtiden (Regeringens skrivelse 2023/24:97). Strategin betonar behovet av såväl tekniska och fysiska anpassningsåtgärder som kunskapshöjande insatser och nya arbetssätt, där klimat- och sårbarhetsanalyser lyfts fram som viktiga verktyg.

Sårbarhetsbegreppet inom kontexten för klimatrelaterad risk har sin grund i IPCC:s tredje (2001) och fjärde (2007) klimatrapport. Där förstås sårbarhet som samspelet mellan exponering, känslighet och anpassningsförmåga (Chen m.fl., 2026). Även om IPCC senare har skiftat fokus mot risk som centralt begrepp (Chen m.fl., 2026) är sårbarhet som konceptuellt ramverk etablerat inom forskning. Sårbarhet inför klimatförändringar kan utforskas såväl kvalitativt (se exempelvis Jonsson & Lundgren, 2015) som kvantitativt. Denna uppsats fokuserar på den kvantitativa uppskattningen av sårbarhet för värme genom ett geografiskt sårbarhetsindex. Ett sårbarhetsindex för värme syftar till att geografiskt kartlägga var i staden som sårbara grupper sannolikt befinner sig vid händelse av värmebölja, och spelar därför en central roll i klimatanpassningsarbetet.

En banbrytande studie inom fältet är Cutter m.fl. (2003) som först presenterade en metod för att kvantitativt bedöma social sårbarhet med Principal Component Analysis (PCA). De använde en mycket stor mängd variabler som de reducerade till ett antal komponenter som de menar kan tolkas som dimensioner av klimatrelaterad sårbarhet – exempelvis ekonomisk status eller åldersrelaterad sårbarhet. Sedan dess har sårbarhetsindex konstruerats för olika geografiska nivåer (städer, regioner, länder) och några huvudsakliga metodologiska tillvägagångssätt etablerats, bland annat PCA.

Wang m.fl. (2026) påpekar att sårbarhetsindex ännu inte fått ett genomslag som vägledande i praktiskt beslutsfattande och därmed riskerar att sakna relevans bortom akademins gränser. Denna studie tar avstamp i det omvända förhållandet med ett redan existerande och till viss grad tillämpat sårbarhetsindex från Malmö stads Miljöförvaltning. Under våren 2026 arbetade jag med att uppdatera det ursprungliga värmesårbarhetsindexet över Malmö stad från 2024 med nya data och beräkningsmetoder – ett index som beräknas genom att sociala och biofysiska indikatorer för värmesårbarhet normaliseras och slås samman additivt. Parallellt arbetade jag med denna uppsats som är en fördjupning i sårbarhetsindexets metodologi genom en jämförelse mellan två etablerade beräkningsmetoder – PCA och en additiv metod.

Trots det ökade intresset för sårbarhetsindex (Tonmoy m.fl., 2014) ger tidigare forskning inte någon bred vedertagen metodologi utan bara generella ramverk för konstruktionen av sårbarhetsindex (Serkendiz, 2026; Wang m.fl., 2026). Det finns alltså ett behov av djupare förståelser för hur känsligt resultatet är för olika beräkningsmetoder (Reckien, 2018). Denna uppsats bidrar till fältet genom att jämföra utfallet av två olika tillvägagångssätt för att kombinera sårbarhetsindikatorer till ett gemensamt index. Uppsatsen fokuserar på de sociala

sårbarhetsindikatorerna och angriper ett centralt problem inom sårbarhetsforskning: hur bör vi kombinera indikatorerna för att uppskatta fördelningen av sårbarhet inom en befolkning? Wang m.fl. (2026) kallar detta för indexets "hierarkiska schema" (hierarchical scheme) och undersöker för- och nackdelar med både "induktiva" (PCA) och "deduktiva" (additiv) utformningar. På ett liknande sätt delar Reckien (2018) in metoderna i de huvudsakliga kategorierna "variabeladdition" och "variabelreduktion". Singh (2023) använder begreppet "Unweighted Additive Overlay" för det jag kallar additiva index och beskriver det som den enklaste metoden för sårbarhetsindex, följt av det mer komplexa "Weighted Additive Overlay" och slutligen mest komplexa PCA. PCA är ett sätt att reducera mångdimensionella data till ett fåtal variabler, så kallade komponenter, vilket görs genom att hitta de linjära kombinationer av variablerna som ger högst varians (Greenacre m.fl., 2022). De resulterande komponenterna är okorrelerade och representerar de huvudsakliga samvariationsmönstren mellan variablerna och därmed de viktigaste dimensionerna av sårbarhet utifrån de valda indikatorerna. Genom dessa sårbarhetsdimensioner kan ett sårbarhetsindex konstrueras. De huvudsakliga fördelarna med PCA inkluderar dimensionsreduktion och hantering av multikollinearitet – alltså starkt samvarierande variabler (Chen m.fl., 2026).

1.1 Syfte och frågeställningar

Syftet med studien är att analysera hur olika metoder för att beräkna ett värmesårbarhetsindex påverkar den rumsliga identifieringen av sårbara områden i en stad. Studien jämför en datadriven metod (PCA) med en additiv metod och undersöker hur skillnaderna i indexvärden kan förstås utifrån metodologiska antaganden. Inom litteraturen inkluderas oftast även variabler för exponering (Cutter m.fl., 2003) på något sätt i sårbarhetsindexet, men denna studie begränsar sig till endast de sociala indikatorerna för värmesårbarhet. Forskningsfrågorna är:

- Hur skiljer sig ett PCA-baserat värmesårbarhetsindex från ett additivt, oviktat index i termer av rumslig fördelning och rangordning av områden?
- Hur kan skillnader mellan indexmetoderna förstås utifrån de metodologiska antagandena?
- Vilka styrkor och svagheter kan tillskrivas respektive metod utifrån resultaten?

2. Metod

2.1 Datakällor

De två sårbarhetsindexen som konstrueras i den här uppsatsen baseras på åtta indikatorer (tabell 1) som representerar olika aspekter av sårbarhet för värmebölja. Valet av indikatorer, som är ett grundläggande steg i processen (Wang m.fl., 2026), skedde inte inom ramen för uppsatsen utan genomfördes i ett tidigare projekt på Miljöförvaltningen i Malmö stad som är dokumenterad av Sonesson m.fl. (2024). Indikatorerna valdes ut tillsammans med forskare från Stockholm Environment Institute och lokala experter från bland annat Röda Korset och Stadsmissionen (Sonesson m.fl., 2024). Wang m.fl. (2026) menar att litteraturoversikt, subjektiva bedömningar och expertutlåtanden är vanliga strategier för detta steg, varav samtliga är tillämpade till någon grad i detta fall. De biofysiska variablerna för värmeexponering är utelämnade eftersom de inte är relevanta utifrån uppsatsens avgränsning och syfte.

Tabell 1, samtliga indikatorer för värmesårbarhet. Kolumnen "Påverkar sårbarhet" anger om högre variabelvärden associeras med högre sårbarhet (+) eller lägre sårbarhet (-).

Faktor	Datakälla	År	Upplösning	Påverkar sårbarhet	Kommentar
Små barn	Andel under 5 års ålder. Från SCB:s befolkningsstatistik	2025	DeSO	+	Beräknat som andelen under 5 års ålder av samtliga åldersgrupper.
Äldre	Andel över 65 års ålder. Från SCB:s befolkningsstatistik	2025	DeSO	+	Beräknat som andelen över 65 års ålder av samtliga åldersgrupper.
Hälsostatus	Genomsnittligt antal registrerade sjukdagar. Från Försäkringskassan och SCB, men tillgängligt på DeSO-nivå genom Malmö kommun.	2024	DeSO	+	Sjukdagar gäller för åldrar 20–64.
Ensamhet	Andel ensamstående utan barn. Från SCB:s befolkningsstatistik	2025	DeSO	+	
Ekonomisk status	Medelvärde disponibel inkomst. Från SCB:s hushållens ekonomi	2024	DeSO	-	Summan av alla skattepliktiga och skattefria inkomster minus skatt och övriga negativa transfereringar.
Boendeform	Andel personer som bor i småhus. Från SCB:s hushållens ekonomi	2024	DeSO	-	
Mobilitet	Andel personbilägare. Från SCB:s fordonsstatistik	2024	DeSO	-	Antal bilar dividerat med befolkningsantalet.
Bostadsarea	Genomsnittlig bostadsarea per person. Från Boverket segregationsbarometern	2023	DeSO (2018)	-	Den geografiska enheten är DeSO 2018 som omvandlas till DeSO 2025.

2.2 Demografiska statistikområden

Den geografiska enheten för samtliga datakällor är Malmös 209 demografiska statistikområden (DeSO). Denna geografiska indelning är skapad av Statistiska Centralbyrån (SCB) och användes första gången år 2018 då Malmö kommun delades in i 192 DeSO-områden. Eftersom städer förtätas och befolkningsmönster ändras så reviderades områdena och DeSO-gränserna år 2025 (SCB, u.å.).



Figur 1 visar Malmös DeSO-gränser som vita linjer. Ett område kring Pildammsparken visas närmare för att illustrera områdenas storlek i centrala Malmö. Notera att DeSO-gränserna sträcker sig ut i Öresund men klippts till kustlinjen. Flygfoto över Malmö från 2024 är offentligt tillgängligt på stadsatlas.malmo.se

Eftersom DeSO tar hänsyn till befolkningmängden är områdena större mot ytterkanterna i staden där färre är bosatta och mindre i centrala delar där befolkningstätheten är större (figur 1). En indikator (bostadsarea) var bara tillgänglig i 2018 års version av DeSO. Detta löstes genom att överlagra DeSO 2025 och räkna ut medelvärdet inom dess geografi, med en metod motsvarande 'Zonal Statistics' i många GIS-mjukvaror. Detta utgör en felkälla men eftersom de flesta DeSO-gränser är oförändrade mellan 2018 och 2025 och att endast en indikator led av detta problem så kan inverkan på slutindexet anses liten.

2.3 Konstruktion av index

De huvudsakliga stegen i konstruktionen av ett sårbarhetsindex är val av indikatorer, transformering, normalisering, vägning och aggregering, och för PCA tillkommer ett urval av komponenter (Wang m.fl. 2026). Tidigare beskrev jag hur urvalet av indikatorer gjordes och nedan beskrivs de kvarvarande huvudsakliga stegen. I projektet har uteslutande mjukvara med öppen källkod (open source) använts för analys och visualisering. De huvudsakliga mjukvarorna är:

- Python med biblioteken Geopandas (0.14.3), Matplotlib (3.9.2) och scikit-learn (1.5.2)
- R med bibliotek Psych (2.6.3)
- QGIS för macOS (3.36.0)

2.3.1 Korrigering för skeva fördelningar

Samtliga indikatorers fördelningar analyserades för skevheter där tre av de åtta variablerna bedömdes som lognormalfördelade, alltså att logaritmen av dataserien var normalfördelad (eller åtminstone mindre skev). Det metodologiska antagandet som görs när vi tar logaritmen av dessa skeva fördelningar är att kopplingen mellan indikatorn och sårbarheten inte är linjär. Exempelvis så innebär det att vi antar att den som har dubbel disponibel inkomst (1000 tkr) från ett annat höginkomsthushåll (500 tkr) inte är hälften så sårbar i termer av inkomst. Eftersom båda dessa höginkomsttagare inte är sårbara utifrån inkomst vill vi att värden ska ligga nära varandra efter korrigeringen. När vi tar logaritmen av indikatorn så trycks höga värden ned till liknande nivåer medan variationen i de lägre värdena blir synliga i fördelningen. Den främsta motiveringen för logtransformering är alltså att vi inte vill att några få extrema värden ska dominera den relativa fördelningen av sårbarhet. Även om normalisering är ett ofta diskuterat område i litteraturen för sårbarhetsindex så är frågan om logtransformering nästan helt frånvarande – ett undantag är Wang m.fl. (2026) som gör logtransformering av skeva indikatorer. Följande indikatorer korrigerades genom att ta logaritmen:

- Ekonomisk status (disponibel inkomst)
- Äldre
- Mobilitet (andel bilägare)

2.3.2 Riktning och normalisering

För att ge indikatorerna samma riktning i termer av sårbarhet så multiplicerades vissa indikatorer (se tabell 1) med -1, så att högre värden alltid innebär ökad sårbarhet (Reid m.fl., 2009; Singh, 2023). För det additiva indexet normaliseras alla indikatorer till värden mellan 0–1 enligt följande formel:

$$\text{Ekvation 1} \quad X' = \frac{X - X_{\min}}{X_{\max} - X_{\min}}$$


Där X är värdet som ska normaliseras, $X_{\min}$ är det minsta värdet i dataserien (exempelvis området med minst boarea per person) och $X_{\max}$ är det högsta värdet i dataserien. X' är det resulterande värdet mellan 0 och 1, där det minsta originalvärdet blir 0 och det högsta originalvärdet blir 1. Indata för PCA normaliseras genom att räkna ut standardpoäng (standard score eller z-score på engelska), alltså subtrahera medelvärdet och dividera med standardavvikelsen för respektive indikator (Greenacre m.fl., 2022).

2.3.3 Aggregering av additivt index


Aggregering till det slutgiltiga additiva indexet görs genom att summera samtliga indikatorers värden och igen normalisera det slutgiltiga indexet till mellan 0–1 enligt ekvation 1.

2.3.4 Sårbarhetsindex med PCA

En förutsättning för PCA är att det finns korrelationer mellan variablerna eftersom dessa är grunden för de strukturer som PCA ska hitta. Figur 2 visar korrelationen mellan samtliga indikatorer där min bedömning är att det finns starka korrelationer och att PCA därför förväntas kunna hitta relevanta komponenter, så som ekonomisk status och bostadsarea (0.86) och ensamhet och boendeform (-0.77). PCA analysen gjordes med R-paketet Psych som har funktionalitet för varimax-rotation – en metod som används av andra inom fältet (Wang m.fl., 2026). Varimax är mycket vanligt för PCA-baserade sårbarhetsindex och innebär en rotation inom respektive komponent för att maximera skillnaden mellan starka och svaga loadings (beskrivs nedan) och därmed underlätta tolkning (Johnson m.fl., 2012; Reid m.fl., 2009).



Figur 2, korrelationsmatris (Pearsons) över samtliga indikatorer. Indikatorerna har korrigerats för skeva fördelningar men har sin originalriktning enligt tabell 1.



Figur 3 visar komponenternas egenvärde och gränsen för Kaiser-kriteriet.

En scree plot över egenvärde (eigenvalue) hjälper oss besluta hur många komponenter vi ska behålla. De första komponenterna är per definition de viktigaste strukturerna hos variablerna

medan de sista antas representera slumpmässig variation (Greenacre m.fl., 2022). Kaiser-kriteriet är en vanligt förekommande princip inom fältet som säger att behålla de komponenterna med ett egenvärde större än 1 och alltså representerar variationen av åtminstone en originalvariabel (Patil m.fl., 2008). Kriteriet har kritiserats för att vara för tillåtande och leda till att för många komponenter behålls (Patil m.fl., 2008), men används här ändå eftersom det är mycket vanligt inom fältet (exempelvis Chen m.fl., 2026; Nayak m.fl., 2018; Reckien, 2018). Det andra kriteriet som jag tillämpar är att komponenten måste vara övervägande riktad mot sårbarhet och inte innehålla en blandning av både starkt negativa och positiva loadings. Detta kriterium är sällan explicit formulerat i litteraturen men impliceras ofta genom att indikatorer väljs ut eller transformeras på ett sådant sätt att tydliga sårbarhetskomponenter uppnås. Utifrån dessa två kriterier behålls de tre första komponenterna.

Tabell 2. Till vänster är loadings avrundade till 2 decimaler. Till höger är en förenkling av loadings enligt metod från Jolliffe (2002) där + innebär en starkare positiv loading, (+) en måttlig positiv loading och vice versa för negativa värden. Samtliga variabler är riktade så att högre värden innebär högre sårbarhet. PC står för 'principal component'.

	PC1	PC2	PC3		PC1	PC2	PC3
Mobilitet	0.20	0.49	-0.38	Mobilitet		+	(-)
Ensamhet	0.04	0.97	-0.03	Ensamhet		+	
Ekonomisk status	0.85	0.15	-0.11	Ekonomisk status	+		
Hälsostatus	0.34	0.14	0.04	Hälsostatus	(+)		
Boendeform	0.31	0.72	-0.05	Boendeform	(+)	+	
Bostadsarea	0.90	0.10	-0.29	Bostadsarea	+		(-)
Sårbara åldersgrupper	-0.22	-0.04	0.96	Sårbara åldersgrupper			+

Tabell 2 visar de loadings som gäller för respektive komponent. Loadings kan förstås som ett 'recept' för att skapa en komponent. När vi rör oss i positiv riktning av den komponenten så lägger vi till mycket av de originalvariabler som har höga positiva loadings (Greenacre m.fl., 2022). Negativa loadings innebär att vi rör oss i negativ riktning för den originalvariabeln när komponenten ökar i värde. Om en komponent har fler höga värden innebär det att de utgör samvarierande signaler, som exempelvis bostadsarea och ekonomisk status. Eftersom vi har riktat variablerna så att höga värden (positiva standardpoäng) alltid innebär mer sårbarhet så vill vi i det ideala fallet ha komponenter med bara positiva loadings för att representera sårbarhet. I mitt fall har de två första komponenterna en tydlig övervikt mot sårbarhet medan den tredje är ett gränsfall (medelvärde för PC3:s loadings är precis positivt). Notera att jag valde att slå ihop indikatorerna för unga (<5 år) och äldre (>65 år) till den nya variabeln 'Sårbara åldersgrupper' eftersom det efter några experiment med PCA-metoden visade sig vara ett sätt att ha samtliga originalvariabler representerade i komponenterna som positiva loadings. Sådan typ av manipulering av variabler i samband med PCA förekommer i litteraturen, exempelvis Reid m.fl. (2009) som slår samman variablerna ensamboende och äldre. Nedan är min tolkning av de tre komponenterna:

PC1: socioekonomi

- Den här komponenten fångar en geografisk uppdelning av generell socioekonomisk status som finns i Malmö. I den lägre änden av komponenten finns välbärgade hushåll, höga inkomstnivåer, stora villor och invånare med låga sjuktal. Den positiva änden av komponenten består av områden med låg genomsnittlig inkomst där människor bor trängare i lägenheter och har högre sjuktal.

PC2: hushållsstruktur

- Den här strukturen representerar en dimension av hushållsstruktur och potentiell social isolering, där områden med många ensamboende och fler lägenheter kontrasteras mot villaområden med högre biläggande och större hushåll.

PC3: sårbara åldersgrupper

- Detta är en mer svårtolkad komponent eftersom den viktigaste variabeln är sammanslagningen av variablerna för unga och äldre. Dessutom har den två måttligt starka negativa loadings för biläggande och boarea. I syftet att konstruera ett sårbarhetsindex menar jag dock att den är värdefull för att representera områden där sårbara åldersgrupper finns. Komponentens inkluderas därför trots att strukturen är mindre transparent. Ytterligare ett argument att inkludera denna komponent är att låg och hög ålder har en välkänd stark koppling till social sårbarhet i litteraturen (Cutter m.fl., 2003; Reckien, 2018; Reid m.fl., 2009).

Tabell 3, förklaringsgrad, kumulativ förklaringsgrad och vikt per komponent (avrundade värden)

	Förklarad variation	Kumulativ förklarad variation	Vikt
PC1	0.26	0.26	0.38
PC2	0.25	0.51	0.37
PC3	0.17	0.68	0.24


Kolumnen 'Förklarad variation' i tabell 3 anger hur stor del av den totala variationen hos originalvariablerna som förklaras av komponenten. Den totala förklarade variationen i alla tre komponenter är alltså 68%. Detta är något under, men i närheten av andra sårbarhetsindex konstruerade med PCA. De jag tagit del av har ofta en total förklarad variation mellan 70-80% (exempelvis: Hondula m.fl., 2012; Johnson m.fl., 2012; Nayak m.fl., 2018; Reid m.fl., 2009). Jag tilldelade vikter proportionerligt till förklaringsgraden (Wolf & McGregor, 2013) vilket innebär att PC1 och PC2 är ungefär lika viktiga och att PC3 ges något mindre vikt. Slutligen aggregeras komponenternas värden (scores) med respektive vikt och normaliseras till värden mellan 0 och 1 för att kunna jämföras med det additiva indexet (Reckien, 2018).

3. Resultat


3.1 Resultat för PCA-metod

Den socioekonomiska komponentens (PC1) geografiska variation visas i figur 4. Mörkgrön symboliserar områden med mycket hög socioekonomisk status och utgörs av endast två områden i Bellevue och Fridhem. Ljusgrön är områden med god socioekonomi och inkluderar områden i Sibbarp, Hyllieby, Davidshall och Gamla staden samt österut mot Södra Sallerup. Gula områden utgör den största gruppen och utgörs av genomsnittliga värden inom komponenten. Socioekonomisk sårbarhet symboliseras av orange och mörkrött och är som starkast koncentrerat till östra och södra delar av Malmö. Här sticker områden i Norra Sorgenfri, Katrinelund, Rosengård, Heleneholm, Hermodsdal, Lindängen, Almvik och Holma ut som särskilt sårbara.

Figur 5 visar fördelningen av PC2. Gröna områden återfinns oftast en bit från stadskärnan och är statistiskt sett områden med familjer som bor i villa och har med tillgång till bil. Orange och röda områden utgörs av platser som har stor andel ensamboende i lägenhet. Dessa återfinns oftast i centrala delarna av Malmö, och områden i Elstorp, Katrinelund, Norra och Östra Sorgenfri, Dammfri samt ett område i Västra hamnen utmärker sig här som särskilt sårbara.




Figur 4, den geografiska fördelningen av PC1. Grön indikerar lägre och röd högre sårbarhet. Kategorierna kommer från att värdena delas in i fem lika stora spann. Den streckade vertikala linjen i histogrammet visar medelvärdet.




Figur 5, den geografiska fördelningen av PC2.

Figur 6 visar den tredje och sista komponenten för sårbarhet. Den geografiska fördelningen är relativt spridd, vilket är väntat eftersom de två sammanslagna åldersgrupperna har en måttlig negativ korrelation och därför ofta är koncentrerade till olika områden. Områden inom Stadion, Borgmästargården, Ärtholmen, Södertorp och Gröndal sticker ut som ett särskilt sårbart kluster. Även Bellevuegården och enstaka områden i Ribersborg och Limhamns hamnområde är särskilt utsatta sett till ålderssårbarhet.



Figur 6, den geografiska fördelningen av PC3.


Sårbarhetsindex PCA



Figur 7 visar det slutgiltiga sårbarhetsindexet från de viktat aggregerade komponenterna. Resultatet delas in i fem lika stora indexspann där 0 är lägst och 1 är högst värmesårbarhet.


Figur 7 visar det slutgiltiga sammanslagna sårbarhetsindexet för PCA-metoden. Den näst högsta sårbarhetskategorin har relativt stor spridning inom Malmö men har en viss koncentration mot de centrala och södra delarna. Störst sårbarhet är det i områdena Katrinelund, Norra Sorgenfri. Ett kluster utmärker sig även kring sjukhusområdet, Heleneholm, Flensburg, Gröndal, Södertorp och Ärtholmen. Totalt klassificeras 11 områden i den högsta sårbarhetskategorin. Områden med lägst sårbarhet återfinns i Bellevue mot havet samt i ytterkanterna av Malmö, särskilt i de södra delarna. Fördelningen är möjligen lätt bimodal med en större mängd områden koncentrerade kring sårbarhetsvärdena 0.5 och 0.7. Medelvärdet för indexet är 0.60 och är något förskjuten åt högre sårbarheter.

3.2 Resultat för additiv metod



Figur 8 visar samtliga sårbarhetsindikatorer efter riktning, korrigering och normalisering. Gult indikerar hög sårbarhet och blått låg sårbarhet.

Figur 8 visar den geografiska fördelningen för samtliga indikatorer. Vissa indikatorer visar en större sårbarhet för centrala delar, så som mobilitet, ensamhet, ekonomisk status, boendeform och bostadsarea. Åldersindikatorerna samt hälsostatus visar mindre tydliga mönster ur denna aspekt.



Figur 9 visar sårbarhetsindexet framtaget med den additiva metoden. Resultatet delas in i fem lika stora indexspann där 0 är lägst och 1 är högst värmesårbarhet.

Figur 9 visar sårbarhetsindexet för den additiva metoden där samtliga åtta befolkningsvariabler adderas efter en 0–1 normalisering. Sårbarheten är främst koncentrerad i de centrala delarna innanför ringvägen där en majoritet av områden är i den näst högsta sårbarhetskategorin eller högre. Medelvärde är 0.64 och totalt klassificeras 33 områden inom den högsta sårbarhetskategorin. Fördelningen är ojämn och förskjuten mot högre sårbarhetsvärden.


3.3 Skillnader mellan PCA och additivt index

Tabell 4 visar Pearsons korrelation mellan sårbarhetsindexen från respektive metod.

	Additiv	PCA
Additiv	1.00	0.75
PCA	0.75	1.00

Korrelationen (Pearson) mellan den additiva metoden och PCA-metoden är relativt hög med ett värde på 0.75 vilket tyder på ett generellt överensstämmande mellan de två indexen. Vid en visuell jämförelse framträder dock skillnader.

Skillnad mellan additivt och PCA-index



Figur 10 visar skillnaden i indexvärden mellan de två olika metoderna. Blå färg visar områden där den additiva metoden ger högre indexvärden och röd färg visar områden där PCA ger högre indexvärden. Ljusa områden indikerar liten skillnad mellan metoderna. Malmös geografiska statistikområden är överlagrade för att lättare kunna tolka och beskriva resultatet.

I figur 10 syns skillnaderna i indexvärde mellan de två metoderna. Det generella mönstret som framträder är att de centrala delarna (område 1 och 9) tilldelas högre indexvärden för den additiva metoden. Även område 10 och 14 har generellt högre värden med den additiva metoden. PCA tenderar i stället att ge relativt högre värden längre från stadskärnan – särskilt områden 3, 4, 5, 6, 7 och 12. Generellt ger den additiva metoden högre indexvärden. De fem kategorierna för skillnaden i sårbarhetsindexen är centrerade runt 0 (ingen skillnad mellan index) där 7 områden hamnar i den mest extrema kategorin för högre additivt index. Inga områden klassificeras i motsvarande extrema kategori för PCA-metoden vilket visar att PCA-metoden inte producerar stora överskattningar av sårbarhet i relation till det additiva indexet.

Tabell 5 visar korrelationen mellan individuella indikatorer och skillnaden i indexvärde. 7 av 8 indikatorer korrelerar negativt mot indexskillnaden vilket innebär att dessa sårbarhetsindikatorer tenderar att vara högre där det additiva indexet är högre relativt till PCA, och vice versa. De två viktigaste indikatorerna som driver skillnaden i indexvärdet är mobilitet (antal bilar per person) och boendeform (andel boende i småhus) vilket är variabler som har en tydlig uppdelning mellan centrala och yttre delar av Malmö. Indikatorn äldre är viktig för att driva skillnaden där PCA ger högre värden än den additiva metoden.


Figur 11 visar en konfusionsmatris över sårbarhetskategorierna från respektive metod (samma kategorier som visas i figur 7 och 9). De två indexen har en generell överensstämmelse och den vanligaste kombinationen är där båda index är klassificerade som 4. Det finns dock viktiga skillnader, särskilt i de högre klasserna där PCA tenderar att ge lägre värden än det additiva indexet. I de lägre klasserna finns exempel på det omvända förhållandet där PCA klassificerar 14 områden som klass 3 och det additiva indexet har klass 2.

Figur 12 (nästa sida) visar ett punktdiagram över båda metodens indexvärden gentemot varandra. En linjär regression mellan indexen visar en korrelationskoefficient nära 1 och en något positiv intercept. För PCA:s indexvärden <0.4 ger metoden generellt högre värden än den additiva. I spannet 0.4–0.8 för PCA återfinns den största delen av indexresultat där den additiva metoden ger högre värden.


Tabell 5 visar korrelationen mellan indexskillnaden (figur 10) gentemot respektive riktad indikator. Positiva värden innebär en positiv korrelation mellan indikatorn och att PCA har högre värden relativt det additiva indexet, och vice versa.

Korrelation mot indexskillnad	
Äldre	0.59
Yngre	-0.30
Ensamhet	-0.37
Ekonomisk status	-0.44
Bostadsarea	-0.45
Hälsostatus	-0.48
Boendeform	-0.63
Mobilitet	-0.73

Konfusionsmatris indexkategorier



Figur 11 visar en konfusionsmatris för sårbarhetsklasserna i respektive metods sårbarhetsindex där 1 (indexvärden 0–0.2) är lägsta och 5 (indexvärden 0.8–1) är högsta klassen. Cohens kappa är 0.25



Figur 12, regressionsanalys mellan PCA (x) och additiv metod (y) för samtliga 209 områden. Ovanför den streckade linjen (ljusblått) är områden där den additiva metoden ger högre indexvärden än PCA och det ljusröda området visar det omvända. Den belagda blå linjen visar en linjär regression mellan indexvärdena.

Tabell 6 visar korrelationen mellan originalvariablerna (riktade så att högre värden innebär ökad sårbarhet) och respektive sårbarhetsindex.

	Additivt index	PCA index
Mobilitet	0.70	0.29
Ensamhet	0.72	0.63
Ekonomisk status	0.74	0.60
Hälsostatus	0.56	0.33
Boendeform	0.90	0.64
Bostadsarea	0.69	0.53
Äldre	-0.22	0.23
Yngre	0.18	-0.03

När varje individuell indikator korreleras mot respektive index (tabell 6) framgår det att det additiva indexet generellt har högre korrelation mot originalvariablerna jämfört med PCA. Ett undantag är indikatorn för äldre som korrelerar starkare mot PCA-indexet än det additiva.

4. Diskussion

Syftet med studien var att undersöka hur två olika metoder för konstruktionen av värmesårbarhetsindex påverkar den rumsliga identifieringen av sårbara områden i Malmö. Resultaten visar att metoderna i stora drag identifierar liknande övergripande mönster, men att betydande skillnader uppstår i hur sårbarhet fördelas mellan Malmös centrala och yttre områden samt hur starkt vissa indikatorer påverkar slutindexet. Diskussionen nedan behandlar hur dessa skillnader kan förstås utifrån de olika metodologierna samt vilka styrkor och svagheter som framkommer för respektive metod i denna studie. Avsnittet avslutas med en diskussion om studiens begränsningar samt praktiska tillämpning och framtida forskning.

4.1 Skillnader mellan additiv metod och PCA

På en generell nivå ger båda index ett till största del överensstämmande resultat med en korrelation på 0.75 (tabell 4), en konfusionsmatris med någorlunda överensstämmande kategorier och ett måttligt positivt kappavärde (figur 11) samt en regressionsanalys mellan indexvärdena med en variationskoefficient (r^2) på 55,8% (figur 12). Sett till fördelningen av indexvärden ger det additiva indexet generellt högre och mer koncentrerade sårbarhetsvärden (figur 9) medan PCA ger jämnare och mer differentierade resultat (figur 7). Detta är jämförbart med en liknande studie (Wang m.fl., 2026) som får $r^2=42\%$ mellan ett additivt och PCA-index.

Även om det övergripande resultatet är överensstämmande så framträder intressanta skillnader när resultaten jämförs geografiskt (figur 10). Särskilt slående är de centrala delarna kring Gamla staden och Möllevången samt Rosengård, Hyllievång och Kroksbäck där det additiva sårbarhetsindexet ger närmast konsekvent högre värden än PCA. Att stadskärnor tilldelas högre indexvärden är inte ovanligt inom litteraturen (Macnee & Tokai, 2016; Reid m.fl., 2009), men resultatet visar att metodvalet kan ha betydelse för om effekten blir mer eller mindre framträdande. Eftersom många indikatorer visar en geografisk uppdelning mellan Malmös centrala och yttre delar är det väntat att båda index visar detta generella mönster (figur 7, 9). PCA reducerar dock samvarierande variabler till ett färre antal komponenter (Jolliffe, 2002) och korrigerar därmed för att samvarierande variabler får ett oproportionerligt genomslag (Chen m.fl., 2026). Nettoeffekten blir att sårbarheten i de centrala områdena inte får lika höga värden jämfört med den additiva metoden, där höga indikatorvärden för centrala delar adderas utan någon hänsyn till samvariation. Detta syns genom att skillnaden i indexvärden är starkt korrelerade till variabler som visar en uppdelning mellan centrala och yttre områden, så som boendeform och mobilitet (tabell 5, figur 8). Dessa indikatorer har en hög korrelation (0.69, figur 2) och reduceras därmed till en dimension i den andra komponenten (hushållsstruktur) för PCA (tabell 2), medan det additiva indexet låter dessa signaler 'räknas dubbelt'.

Det finns dock intressanta undantag där PCA ger högre värde i de inre delarna, särskilt i område 8 och 13 (figur 10). Detta kan förstås genom att titta på den geografiska fördelningen av äldre (figur 8) som är hög för områdena Gröndal, Södertorp och Borgmästargården samt kringliggande områden. För det additiva indexet försvinner denna signal till stor del eftersom den utgör en av åtta sammanslagna indikatorer medan den för PCA är mycket tydlig i PC3 – komponenten för sårbara åldrar (figur 6). Detta är ett av de tydligaste fallen av hur PCA lyckas lyfta fram dimensioner av sårbarhet som den additiva metoden inte på motsvarande sätt gör. Ett liknande men mindre extremt fall gäller för Norra Sorgenfri och Katrinelund (område 2, figur 10) där PCA ger högre värden gentemot den additiva metoden. Detta kan förstås genom komponenten för hushållsstruktur PC2 (figur 5) som ger höga sårbarhetsvärden för just dessa områden och därför

ger högre värden jämfört det additiva indexet. Att PCA får genomslag för specifika sårbarhetsdimensioner och därmed 'går emot' majoriteten av individuella indikatorer är en förklaring till att PCA generellt får lägre korrelation mot originalvariablerna än den additiva metoden (tabell 6). Det additiva indexet får högre korrelation med originalvariablerna eftersom indexet består av summan av dem. En lägre direkt korrelation mellan indikatorer och PCA-indexet tolkar jag som ett uttryck för att metoden fångar bredare underliggande strukturer av samvariation snarare än att direkt summera indikatorerna.

4.2 Tolkning av PCA-komponenterna och Malmös geografiska mönster

En styrka med PCA är att komponenterna i sig själva medför en fördjupad analys av värmesårbarhetens dimensioner och geografiska fördelning (Chen m.fl., 2026) och därmed säger något viktigt om Malmö stad i termer av social sårbarhet för värmebölja redan innan ett indexvärde har beräknats. Komponenterna kan diskuteras i relation till tidigare studier som använt PCA för värmesårbarhetsindex och inom fältet är det vedertaget att de mest betydelsefulla indikatorer för värmesårbarhet inkluderar ålder, socioekonomisk status, ras/etnicitet, utbildningsnivå och social isolering (Cutter m.fl., 2003; Johnson m.fl., 2012).

Den första och viktigaste komponenten är socioekonomi (figur 4) som förklarar 26% av variationen hos indikatorerna (tabell 3) och har starka loadings för bostadsarea och ekonomisk status, samt måttligt starka loadings för hälsostatus och boendeform (tabell 2). Det är vanligt inom fältet att den första komponenten innehåller ekonomisk status eller motsvarande mått på låg inkomst (Hondula m.fl., 2012; Johnson m.fl., 2012; Reid m.fl., 2009; Wolf & McGregor, 2013) men ofta i kombination med andra indikatorer som inte finns representerade i denna studie, exempelvis ras/etnicitet. Dimensionen visar en stark koppling med stadstypologin där låg sårbarhet oftast kopplas till villakvarter och hög sårbarhet till miljonprojekts-områden. Ett undantag är områdena i västra hamnen som har hög socioekonomisk status men som nästan bara består av lägenheter. Att detta typ av boende (lägenheter i stället för småhus) skulle innebära värmesårbarhet på samma sätt som att bo i lägenhet i andra delar av Malmö är tveksamt och är en aspekt att ifrågasätta denna indikatorns sårbarhetskoppling utifrån. Om indikatorerna skulle manipulerats så att exempelvis bara trångbodda lägenheter utgjorde boendeforms-sårbarhet så skulle kanske västra hamnen ges ett lägre sårbarhetsvärde då denna indikator ingår till betydande grad i både PC1 och PC2.

Även den andra komponenten för hushållsstruktur (figur 5) är representerad i fältet, men då ofta kallad social isolering (Macnee & Tokai, 2016; Nayak m.fl., 2018; Reid m.fl., 2009; Wolf & McGregor, 2013). Ensamhet och social isolering kopplades även mycket starkt till sårbarhet av deltagare även i en kvalitativ studie (Jonsson & Lundgren, 2015). I min studie utgörs denna komponent huvudsakligen av områden med många ensamboende, många lägenheter och lågt biläggande. Men även om denna sårbarhetsdimension har stark koppling till litteratur så kan den problematiseras. Ett av områdena med högst sårbarhet enligt PC2 är Katrinelund där Rönne, Malmös största studentboende, ligger. Även om man kan tänka sig att studenter kan ha viss generell sårbarhet (Inostroza m.fl., 2016) så är det en kvalitativt meningsfull skillnad gentemot social isolering grundat i ett mer samhälleligt utanförskap, vilket jag tror ofta är vad som åsyftas i litteraturen. Detta kan motivera en sammanslagning av indikatorer som äldre och ensamma (Macnee & Tokai, 2016) eller ensamma med låg inkomst.

Den tredje komponenten fångar en dimension av värmesårbarhet grundad i ålder (figur 6) – även den välgrundad i litteraturen. Av de PCA-sårbarhetsstudier jag har tagit del av är dock hög ålder (>65 år) vanligare som indikator än låg ålder (<5 år) som förekommer i Azhar m.fl., (2017), Cutter m.fl. (2003) och Inostroza m.fl. (2016). För att få med åldersindikatorerna i en komponent som mötte

mina kriterier behövde de adderas samman till en variabel, vilket jag inte funnit exempel på i litteraturen för just dessa indikatorer. Detta belyser något av en svårighet med PCA – att det kan uppstå spänningar mellan vår teoretiskt drivna förståelse, och det statistiskt drivna urvalet av vilka indikatorer som får betydelse. Lösningen i mitt fall blev en sammanslagning av indikatorerna, vilket är ett exempel på de subjektiva inslag som kan introduceras av metoden.

Ett intressant resultat är just att hög ålder inte korrelerar tydligt med de andra sårbarhetsindikatorerna i den här studien (figur 2). Områden med hög andel äldre tenderar i stället att korrelera med relativt sett större biläande, större bostadsareor och högre disponibla inkomster. Detta är i sig en intressant insikt om Malmös sociala struktur där, till skillnad från andra studier (Macnee & Tokai, 2016; Reid m.fl., 2009), socialt isolerade äldre inte är en grupp som framträder i analysen.

Det faller utanför uppsatsens syfte att närmare analysera komponenterna ur en samhällsvetenskaplig lins, men det föreslås som ett viktigt perspektiv för att praktiskt tillämpa denna typ av studie inom exempelvis en kommun. Ett stort värde med PCA som framkommer i studien är att strukturerna i sig själva är ett intressant resultat som kan arbetas med ur korskvetenskapliga perspektiv i en akademisk kontext och förvaltningsövergripande på kommunal nivå. Exempelvis aktualiserar komponenterna och deras geografiska mönster frågor inom ämnen som segregation, urban struktur, bostadstyper, tillgång till resurser och vidare sociala frågor. PCA kan därför på många sätt ses som ett kvantitativt sätt att arbeta med intersektionalitet (Crenshaw, 1989) genom de olika dimensioner av sårbarhet som framträder i analysen.

4.3 Metodologiska implikationer – för och nackdelar

Hittills har diskussionen mestadels berört PCA-metoden – något som speglar den höga komplexiteten både i utförande och resultat som PCA har i jämförelse mot den enklare additiva metoden. I det här avsnittet diskuterar och sammanfattar jag styrkor och svagheter för respektive metod som framkommit i analysen. PCA är som tidigare nämnt mer komplex än det additiva indexet (Singh, 2023) vilket på många sätt medför ett djupare och mer intressant resultat, men det har framkommit både för- och nackdelar:

- **Fördelar PCA**
 - Dimensionsreduktion, hantering av många och samvarierande indikatorer
 - Meningsfulla komponenter för analys, fördjupad förståelse
 - Datadriven viktning som adresserar ett centralt problem i fältet
- **Nackdelar PCA**
 - Mindre transparens gentemot exempelvis beslutsfattare eller allmänheten
 - Kräver subjektiva inslag i behandling av indikatorer och urval av komponenter
 - Indikatorer med låg samvariation kan exkluderas även om de är teoretiskt viktiga

Det additiva indexet medför sina egna för- och nackdelar:

- **Fördelar additivt index**
 - Enkel, transparent metod som inte kräver specialiserad kunskap inom statistik
 - Flexibilitet i valet av indikatorer, kan utformas efter lokal kontext (Serkendiz, 2026)
 - Resultat är enkelt att jämföra över år om samma indikatorer används
- **Nackdelar additivt index**
 - Känslig för samvariation, kräver noga valda indikatorer

- Ger inte självklart en djupare förståelse av sårbarhet utan bara en addition av indikatorer
- Skev och ojämn sårbarhetsfördelning
- Oviktade indikatorer

Det går inte utifrån denna jämförelse att säga vilken metod som bättre identifierar och kartlägger värmesårbarhet – något som aldrig syftet med studien. Däremot går det utifrån resultaten att diskutera under vilka omständigheter respektive metod kan lämpa sig bättre. PCA adresserar vissa problem som finns med den additiva metoden, men ersätter dem samtidigt med nya metodologiska avvägningar som ställer högre krav på utföraren. Detta, menar jag, gör PCA mer lämplig i exempelvis akademisk eller andra specialiserade miljöer där en djupare analys är värdefull. Men som Wang m.fl. (2026) pekar ut så har sårbarhetsindex inte fått ett genomslag som underlag för beslutsfattare och saknar därmed idag viss relevans i praktiken. Här riskerar en något svårförstådd analys med låg transparens göra metoden mindre genomslagskraftig som verktyg för klimatomställning. Det kan eventuellt vara mer effektivt att med ett fåtal värmesårbarhetsindikatorer (inklusive värmeexponering) visualisera problemen för att vägleda och prioritera omställningsarbete för extremvärme, exempelvis inom kommuner eller regioner.

4.4 Begränsningar och framtida forskning

I det här avsnittet avslutar jag diskussionen med att ta upp några viktiga begränsningar, både i termer av metodjämförelsen mellan PCA och den additiva metoden, men också med sårbarhetsindex som strategi för att geografiskt analysera sårbarhet.

En uppenbar begränsning är att studien begränsade sig till sociala indikatorerna för värmesårbarhet och inte inkluderade indikatorer för värmeexponering och därmed aldrig jämförde två kompletta värmesårbarhetsindex. Hur exponering för klimatrisk ska inkluderas i sårbarhetsindex är inte självklart utifrån litteraturen (Wang m.fl., 2026) och skulle leda till många nya aspekter att analysera och diskutera som inte fick plats inom ramen för denna kandidatuppsats. Det är svårt att veta om jag hade nått andra slutsatser om värmeexponering inkluderats, men det är tydligt att det är ett självklart nästa steg för den här typen av undersökning.

En grundläggande svårighet med metodjämförelsen var också att göra en representativ tillämning av PCA när forskningsfältet inte erbjuder en entydig metodik och analysen i sig själv kräver subjektiva tolkningar och beslut. Ska komponenternas viktas innan aggregering eller ej? Är kriterierna för att inkludera komponenter välgrundade och lämpliga i mitt fall? Studien visar att PCA till stor del är ett hantverk och en erfaren forskare hade kanske gjort andra beslut och fått ett delvis annorlunda resultat. Detsamma gäller för de olika fördelningarna för sårbarhetsindexen. Jag valde att jämföra indexvärdena direkt mot varandra men kanske skulle kvantiler eller någon transformering varit motiverat för att korrigera för distributionsskillnaden. Jag fann inte ett självklart svar i litteraturen eftersom det har gjorts få jämförande studier som denna, och därför valde jag transparens över komplexitet.

En sista tydlig begränsning för jämförelsen är att jag inte valde indikatorer inom ramen för projektet, utan att dessa togs fram i arbetet med det tidigare värmesårbarhetsindexet från Malmö stad, där jag saknade full insyn i processen. En fördel är att valet av indikatorer gjordes i en verklig tillämpning av metodiken och att denna studie kunde ta vid och fokusera just på frågan om hur indikatorerna kan kombineras. En nackdel är att ett viktigt steg i sårbarhetsmetodik inte behandlas i studien och att dessa val eventuellt skulle ha bäring på exempelvis vilka komponenter som skulle framkommit. I en framtida studie kan en jämförelse där PCA bygger på många

indikatorer och det additiva indexet baseras på ett fåtal utvalda indikatorer vara intressant att jämföra. Under projektets gång blev jag till exempel mycket nyfiken på hur utbildningsnivå, kön och svensk/utländsk bakgrund skulle påverka PCA-analysen och vilka komponenter som skulle framträda med dessa indikatorer.

Slutligen vänder jag mig till några generella begränsningar med sårbarhetsindex som metod. Att metoden ens varit genomförbar på en kommunal nivå är tack vare en relativt nya data gjorts tillgängliga med hög befolkningsupplösning, nämligen DeSO-områdena som SCB presenterade första gången år 2018 (SCB, u.å.). Men aggregering av befolkningsdata till dessa områden leder oundvikligen till ett välkänt problem inom fältet som kallas ”modifiable areal unit problem” (Rinner m.fl., 2010; Zhang m.fl., 2018). Problemet uppstår när punktbaserade data aggregeras till geografiska områden – beroende på hur områdena definieras kan de aggregerade värdena skilja sig väsentligt, och de arbiträra gränsdragningarna för DeSO-områden utgör därför en statistisk bias. Att en indikator (bostadsarea) var tillgänglig för den äldre DeSO-versionen och omvandlades med ’Zonal Statistics’ är också en svaghet. En annan svaghet med DeSO är att områdena är baserade på befolkningsmängd men också kan innehålla områden som industriområden och parker där ingen är folkbokförd. Det är ofta arbiträrt vilket DeSO-område exempelvis en park hamnar inom. På samma sätt som DeSO-geometrin har klippts till kustlinjen i min analys kan det argumenteras att andra obebodda ytor bör klippas bort, som exempelvis Reckien (2018) gör. Hamnområdet i norra Malmö är ett särskilt ett problem eftersom dess stora yta kan påverka tolkningen av kartor, trots att personer bara är folkbokförda i ett relativt litet område kring centralstationen. Detta har inte gjorts på grund av tidsbegränsning men föreslås för framtida liknande analyser.

Även om det faller utanför denna studies syfte att utvärdera sårbarhetsindexens förmåga att förutspå värmerelaterade hälsokonsekvenser (Bao m.fl., 2015) så är detta ett viktigt framtida steg. Att utvärdera index är på många sätt en svårare uppgift än att konstruera dem - huvudsakligen som en konsekvens av bristen på lättillgängliga värmerelaterade ohälsodata att överlagra mot indexen. Ett vidare övergripande problem med sårbarhetsindex som metod är frågan om de mest utsatta människorna kan vara utlämnade från indexet, så som papperslösa eller bostadslösa invånare. Några utforskade dimensioner som är vanliga inom litteraturen är kön, etnicitet, funktionsvariation, utbildningsnivå och arbetslöshet (Cutter m.fl., 2003), där ett valideringsarbete skulle kunna tydliggöra vilka viktiga sårbarhetsdimensioner som saknas.

5. Sammanfattning

Syftet med studien var att undersöka hur olika metoder för beräkning av värmesårbarhetsindex påverkar den rumsliga identifieringen av sårbara områden i Malmö. Genom att jämföra ett PCA-baserat index med ett additivt, oviktat index visar resultaten att metoderna i stora drag identifierar liknande geografiska mönster av sårbarhet, men att viktiga skillnader uppstår i hur sårbarheten fördelas och vilka områden som framträder som mest utsatta.

Det additiva indexet gav generellt högre och mer koncentrerade sårbarhetsvärden, särskilt i centrala delar av Malmö där flera indikatorer samvarierar. PCA-metoden gav i stället ett mer differentierat resultat genom att reducera samvarierande indikatorer till underliggande komponenter. Resultaten visar därmed att metodvalet påverkar både rangordningen av områden och vilka dimensioner av sårbarhet som får störst genomslag i slutindexet. Studien visar också att PCA möjliggör en tydligare analys av underliggande sårbarhetsdimensioner, medan den additiva metoden ger en mer direkt representation av de ursprungliga indikatorerna. Båda metoderna har olika styrkor och svagheter beroende på hur de ska användas. PCA ger en djupare insikt i indikatorernas relation till sårbarhet men är i sin komplexitet mindre transparent. Det additiva indexet är lätt att implementera och reproducera men är mindre statistiskt sofistikerat.

I relation till den lilla mängd tidigare forskning som finns bekräftar resultaten att konstruktionen av sårbarhetsindex är metodologiskt känslig och att olika tillvägagångssätt kan ge delvis olika geografiska resultat. Studien pekar på behovet av fortsatt forskning kring metod och validering av sårbarhetsindex för att öka dess nytta och användbarhet i klimatanpassningsarbete.

Referenser

- Azhar, G., Saha, S., Ganguly, P., Mavalankar, D., & Madrigano, J. (2017). Heat Wave Vulnerability Mapping for India. *International Journal of Environmental Research and Public Health*, 14(4), 357. <https://doi.org/10.3390/ijerph14040357>
- Bao, J., Li, X., & Yu, C. (2015). The Construction and Validation of the Heat Vulnerability Index, a Review. *International Journal of Environmental Research and Public Health*, 12(7), 7220–7234. <https://doi.org/10.3390/ijerph120707220>
- Chen, T., Hua, J., Wang, S., & Yin, S. (2026). Heat vulnerability and resilience-oriented solutions for diverse urban residential communities in Guangzhou, China. *Environmental Impact Assessment Review*, 117, 108150. <https://doi.org/10.1016/j.eiar.2025.108150>
- Crenshaw, K. (1989). Demarginalizing the Intersection of Race and Sex: A Black Feminist Critique of Antidiscrimination Doctrine, Feminist Theory and Antiracist Politics. *U. Chi. Legal F.*, 1989, 139.
- Cutter, S. L., Boruff, B. J., & Shirley, W. L. (2003). Social Vulnerability to Environmental Hazards. *Social Science Quarterly*, 84(2), 242–261. <https://doi.org/10.1111/1540-6237.8402002>
- Greenacre, M., Groenen, P., Hastie, T., Iodice D'Enza, A., Markos, A., & Tuzhilina, E. (2022). Principal component analysis. *Nature Reviews Methods Primers*, 2, 100. <https://doi.org/10.1038/s43586-022-00184-w>
- Hondula, D. M., Davis, R. E., Leisten, M. J., Saha, M. V., Veazey, L. M., & Wegner, C. R. (2012). Fine-scale spatial variability of heat-related mortality in Philadelphia County, USA, from 1983-2008: A case-series analysis. *Environmental Health*, 11(1), 16. <https://doi.org/10.1186/1476-069X-11-16>
- Inostroza, L., Palme, M., & Barrera, F. de la. (2016). A Heat Vulnerability Index: Spatial Patterns of Exposure, Sensitivity and Adaptive Capacity for Santiago de Chile. *PLOS ONE*, 11(9), e0162464. <https://doi.org/10.1371/journal.pone.0162464>
- Johnson, D. P., Stanforth, A., Lulla, V., & Lubert, G. (2012). Developing an applied extreme heat vulnerability index utilizing socioeconomic and environmental data. *Applied Geography*, 35(1), 23–31. <https://doi.org/10.1016/j.apgeog.2012.04.006>
- Jolliffe, I. T. (2002). *Principal Component Analysis*. Springer-Verlag. <https://doi.org/10.1007/b98835>
- Jonsson, A. C., & Lundgren, L. (2015). Vulnerability and adaptation to heat in cities: Perspectives and perceptions of local adaptation decision-makers in Sweden. *Local Environment*, 20(4), 442–458. <https://doi.org/10.1080/13549839.2014.896326>
- Macnee, R. G. D., & Tokai, A. (2016). Heat wave vulnerability and exposure mapping for Osaka City, Japan. *Environment Systems and Decisions*, 36(4), 368–376. <https://doi.org/10.1007/s10669-016-9607-4>
- Nayak, S. G., Shrestha, S., Kinney, P. L., Ross, Z., Sheridan, S. C., Pantea, C. I., Hsu, W. H., Muscatiello, N., & Hwang, S. A. (2018). Development of a heat vulnerability index for New York State. *Public Health*, 161, 127–137. <https://doi.org/10.1016/j.puhe.2017.09.006>

- Patil, V. H., Singh, S. N., Mishra, S., & Todd Donovan, D. (2008). Efficient theory development and factor retention criteria: Abandon the 'eigenvalue greater than one' criterion. *Journal of Business Research*, 61(2), 162–170. <https://doi.org/10.1016/j.jbusres.2007.05.008>
- Reckien, D. (2018). What is in an index? Construction method, data metric, and weighting scheme determine the outcome of composite social vulnerability indices in New York City. *Regional Environmental Change*, 18(5), 1439–1451. <https://doi.org/10.1007/s10113-017-1273-7>
- Regeringens skrivelse 2023/24:97. *Nationell strategi och regeringens handlingsplan för klimatanpassning*. <https://www.regeringen.se/contentassets/981309b513244d3eb987e0cf8ff69e37/nationell-strategi-och-regeringens-handlingsplan-for-klimatanpassning-skr.-20232497.pdf>
- Reid, C. E., O'Neill, M. S., Gronlund, C. J., Brines, S. J., Brown, D. G., Diez-Roux, A. V., & Schwartz, J. (2009). Mapping Community Determinants of Heat Vulnerability. *Environmental Health Perspectives*, 117(11), 1730–1736. <https://doi.org/10.1289/ehp.0900683>
- Rinner, C., Patychuk, D., Bassil, K., Nasr, S., Gower, S., & Campbell, M. (2010). The Role of Maps in Neighborhood-level Heat Vulnerability Assessment for the City of Toronto. *Cartography and Geographic Information Science*, 37, 31–44. <https://doi.org/10.1559/152304010790588089>
- SCB. (u.å.). *Demografiska statistikområden (DeSO)*. Statistikmyndigheten SCB. Hämtad 08 maj 2026, från <https://www.scb.se/hitta-statistik/regional-statistik-och-kartor/regionala-indelningar/demografiska-statistikomraden-deso/>
- Serkendiz, H. (2026). Mapping Heatwave Vulnerability: Multidimensional Assessment of Heatwave Vulnerability from an Environmental and Socioeconomic Perspective. *Natural Hazards Review*, 27(1), 05025016. <https://doi.org/10.1061/NHREFO.NHENG-2441>
- Singh, A. M. (2023). Mapping of heat vulnerability in Indian Urban Centres under threat of global warming. *Journal of Applied & Natural Science*, 15(4), 1514–1519. <https://doi.org/10.31018/jans.v15i4.5039>
- Sonesson, L., Toft, E., & Englund, M. (2024). *Extremvärme i Malmö: Vem drabbas och hur kan vi lindra effekterna?*
- Tonmoy, F., El-Zein, A., & Hinkel, J. (2014). Assessment of vulnerability to climate change using indicators: A meta-analysis of the literature. *Wiley interdisciplinary reviews: Climate Change*. <https://doi.org/10.1002/wcc.314>
- Wang, P., O'Brien, F., Son, J.-Y., Heo, S., Bell, M. L., Dubrow, R., & Chen, K. (2026). An updated modeling framework and sensitivity analysis of methodology for the climate health vulnerability index. *Nature Communications*, 17(1), 1417. <https://doi.org/10.1038/s41467-025-68162-w>
- Wolf, T., & McGregor, G. (2013). The development of a heat wave vulnerability index for London, United Kingdom. *Weather and Climate Extremes*, 1, 59–68. <https://doi.org/10.1016/j.wace.2013.07.004>
- Zhang, W., McManus, P., & Duncan, E. (2018). A Raster-Based Subdividing Indicator to Map Urban Heat Vulnerability: A Case Study in Sydney, Australia. *International Journal of Environmental Research and Public Health*, 15(11), 2516. <https://doi.org/10.3390/ijerph15112516>