

Schwarmbasierte Auswertung der OK Lab Feinstaubsensoren im Stuttgarter Stadtgebiet hinsichtlich eines Feinstaub-Luftgütefaktors

Bernd Laquai, 11.3.2017

Das OK Lab Feinstaub Sensor Netzwerk

Das OK Lab (Open Knowledge Lab) Stuttgart betreibt seit Oktober 2015 ein Sensor Netzwerk zur Messung der Feinstaub-Konzentration in der Luft. Schwerpunkt des Netzwerks ist derzeit die Stadt Stuttgart, aber viele Sensoren sind auch in anderen Städten aufgestellt und einige sogar im internationalen Ausland. Das Sensor-Netzwerk unterscheidet sich in zwei Dingen wesentlich von der Messmethodik amtlicher Messstellen: Erstens enthält eine Messstation ein low-cost Sensorbauelement für die Erfassung der Feinstaubkonzentration und zweitens gibt es im Gegensatz zu den wenigen amtlichen Messstellen pro Stadt sehr viele verteilte Messstellen, besonders in der Feinstaub-geplagten Landeshauptstadt Stuttgart. Das Feinstaub-Sensor-Netzwerk ist ein Projekt, das den Nutzen von freien Daten demonstrieren soll. Die ca. 30 Euro teuren Messstellen („Sensoren“) sind bisher zu einem großen Anteil durch ein Crowd-Funding finanziert und werden an Interessierte Bürger als Bausatz ausgegeben. Ein Bürger übernimmt die Patenschaft für eine Messstelle indem er den Sensor bei einem Bastelevent unter Anleitung zusammenbaut, zu Hause aufstellt und dem Sensor Zugang zum eigenen Internet Router gibt. Für die selbstständige Beschaffung und das selbstständige Aufbauen einer Messstation gibt es ebenfalls eine ausführliche Anleitung auf der Projekt-Webseite. Der Sensor sendet dann die gemessenen Daten über das Internet an verschiedene Server des OK Lab, wo die Daten gesammelt und zu einem gewissen Grad auch aufbereitet werden. Die erfassten Rohdaten und die aufbereiteten Daten stehen der Öffentlichkeit zur freien Nutzung zur Verfügung. Hochschulen, andere Forschungseinrichtungen, aber auch Bürger und politische Organisationen sind aufgefordert die Daten weiter auszuwerten und Erkenntnisse zum Thema Feinstaub daraus zu gewinnen und zu veröffentlichen.

Aufbau des OK Lab Sensors

Der „Sensor“, bzw. eine Messstelle des OK Lab, ist denkbar einfach aufgebaut. Sie besteht aus dem eigentlichen Sensorbauelement, derzeit einem SDS011 Feinstaub-Sensormodul der Firma Nova Fitness aus China, einem Feuchte/Temperatur-Sensor vom Typ Aosong DHT22/AM2302 und einer ESP8266 basierten Microcontroller-Platine (NodeMCU von LoLin aus China) mit WLAN Funktionalität. Das SDS011 Sensormodul ist ein Bauteil, das die Feinstaub-Massenkonzentration nach dem Laser-Streulichtverfahren abschätzt und Werte für die Feinstaubklassen PM10 und PM2.5 ausgibt. Mit Strom versorgt werden die Bauteile über ein USB-Steckernetzteil, das mit einem USB-Kabel an die NodeMCU Mikrocontroller-Platine angeschlossen wird. Die Bauteile werden mit Kabelbindern verbunden, fixiert und dann in zwei 90° Drainage-Rohrbögen untergebracht, die anschließend zusammengesteckt werden. Der Sensor liefert nach einer Konfiguration für den Routerzugang im Sekundentakt Messwerte für die Feinstaubklassen PM10 und PM2.5. Diese werden über eine serielle Schnittstelle zum Mikrocontroller übertragen. Der Mikrocontroller aktiviert das SDS011 Sensormodul alle Minute für ca. 10Sek. Gleichzeitig stößt der Mikrocontroller eine Feuchte- und Temperaturmessung an und fragt das Ergebnis über eine one-wire Datenverbindung vom Feuchte-/Temperatursensor ab. Die Messdaten werden vom Mikrocontroller gemittelt und über die WLAN-Verbindung zum den Servern des OK Lab übertragen. Von der Mikrocontroller-Platine erhält der Sensor eine Kennnummer die mitübertragen wird. Serverseitig wird der Datennachricht ein Zeitstempel für den Empfangszeitpunkt zugeordnet, sowie die groben Geokoordinaten und eine weitere anonyme Sensornummer für die Kartendarstellung. Diese Daten werden zusammen mit den Messdaten in eine Datei abgespeichert, die täglich veröffentlicht wird.

Außerdem werden die aktuellen Messdaten der PM10 Feinstaub-Konzentration an den auf ca. 150m gerundeten Geokoordinaten in einer Karte farblich codiert dargestellt.

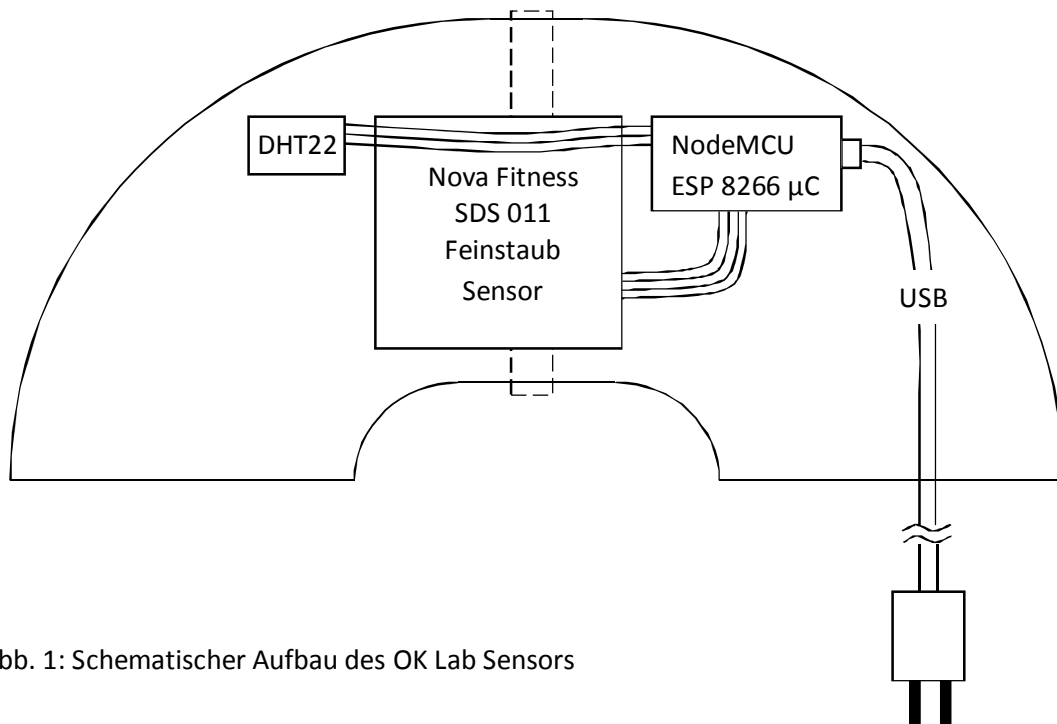


Abb. 1: Schematischer Aufbau des OK Lab Sensors

Schwarmtheorie und Schwarmintelligenz

Das Verhalten von Schwärmen und Rudeln in der Tierwelt hat den Menschen seit jeher beeindruckt. Dies hängt vermutlich damit zusammen, dass der Mensch erkannt hat, dass die Schwarmbildung eine Stärke verleiht, die als einzelnes Individuum nicht zu erreichen ist. Allerdings geht damit auch einher, dass man das eigene Verhalten den Gesetzen des Schwarms zu einem gewissen Grad unterordnen muss, das aber in überlebenskritischen Situationen als das geringere Übel angesehen wird.

Aus diesem Grund wurde die Schwarmtheorie und Schwarmintelligenz auch schnell zu einem speziellen Fachgebiet in der Disziplin der künstlichen Intelligenz. Wie so oft orientiert sich der Mensch daran, was sich in der Evolution der Natur als Vorteil herauskristallisiert hat um daraus auch in der Technik Vorteile zu erreichen.

Das wesentlichste Merkmal eines Schwarms oder Rudels ist, dass sich ein Individuum annähernd so verhält wie seine Nachbarn. Beobachtet man daher das Verhalten eines Individuums im Schwarm, stellt man zwar kein ganz identisches Verhalten fest, aber eine starke Korrelation zu den unmittelbaren Nachbarn. Über den ganzen Schwarm hinweg kann es durchaus zu unterschiedlichem Verhalten kommen, was aber im wesentlichen nur daran liegt, dass die Orientierung am nachbarschaftlichen Verhalten räumlich begrenzt und nicht hundertprozentig ist. Daher stellt man insbesondere an den Schwarmrändern erhebliche Unterschiede im Verhalten zum Schwarmzentrum fest.

Im übrigen scheint auch der Mensch sich oft ein schwarm-basiertes Verhalten zu eigen zu machen, was insbesondere beim Gebrauch der sozialen Medien sehr plakativ sichtbar wird. So beeinflusst beispielsweise die Anzeige der bereits erfolgten Downloads von Videos in einem Videoportal das Verhalten der Besucher sehr erheblich, wenn sie nach einem gewissen Genre an Medien suchen. Der einzelne Besucher lässt sich ganz offensichtlich durch das Verhalten „sozialer Nachbarn“ zu

ähnlichem Verhalten motivieren, so dass über einen Mitkoppel-effekt ein oft sehr einheitliches Schwarmverhalten entsteht. Vorteilhaft ist dieses Verhalten im Hinblick auf das „Mitreden-Können“, was möglicherweise auch eine Art Konkurrenzfähigkeit im Werben um die Gunst von Anderen darstellt. Dies hat auch zum Begriff des „Digital Influencers“ geführt, also jemand, der versucht durch Beeinflussung der digitalen Medien (künstliches Erzeugen von vielen Downloads oder Idolhaftes Auftreten) eine Art Schwarmreferenz zu bilden um andere mitzureißen.

Der hier verwendete schwarmbasierte Ansatz bei Auswertung der OK Lab Sensor-Messdaten unterscheidet sich von anderen Methoden darin, dass zunächst angenommen wird, dass die einzelnen periodisch erfassten Messdaten zeitdiskrete stochastische Prozesse sind, die untereinander deutlich korreliert sind. Die Messdaten selbst sind dabei allerdings nur an bestimmten geographischen Positionen aufgenommene Zeitverläufe der vorherrschenden weit-verteilten Feinstaub-Konzentration. Die Sensoren liefern also Einblicke an bestimmten Stellen in eine räumlich weit ausgedehnte „Feinstaub-Wolke“, die hinsichtlich ihrer Dichte von Ort zu Ort zwar unterschiedlich sein kann, aber dennoch eine gewisse Kohäsion hinsichtlich der meteorologischen Schwankungen hat. Diese, durch die hohe Diffusivität des Feinstaubes bedingte Kohäsion der Konzentrationen sorgt dafür, dass unter dem Einfluss der Wetterbedingungen korrelierte Schwankungen an den einzelnen Aufstellorten der Sensoren entstehen, und so auch das Sensor-Netzwerk selbst ein Schwarmverhalten erhält.

Daher ist es sinnvoll zunächst das Schwarmzentrum im Bereich der stärksten sichtbaren Schwankungen zu wählen, dann die Korrelationen der einzelnen Sensor-Messkurven untereinander auf Plausibilität zu prüfen und dann ihre Korrelation zum Schwarmzentrum zu ermitteln. Liegt eine starke Korrelation vor, dann lässt sich eine ganz spezifische Signatur für eine gegebene Feinstaub-Episode in Form eines Schwarmmittelwerts ermitteln. Dieser Mittelwert wird dann nicht wie sonst üblich entlang der Zeitachse berechnet, sondern über die Werte aller Sensoren jeweils für einzelne aufeinanderfolgende diskrete Zeitpunkte auf der Zeitachse. Die Abfolge der Schwarmmittelwerte über der Zeit gibt dann das gemeinsame Verhalten des Schwarms (seinen „Gleichtakt“) über Zeit wieder. Genauso kann dann auch die Ablage vom Schwarm als Schwarmstreuung ermittelt werden, die angibt, wie homogen oder kohärent der Schwarmverlauf ist. Über diese hier vorgestellten Schwarmkenngrößen hinaus sind noch viele weitere schwarmbasierte Analysen denkbar, die auf einer Statistik entlang benachbarter „Sensorindices“ gemacht werden können, die hier nicht diskutiert sind.

Kalibrierung

Eine wichtige Eigenschaft eines Schwarmindividuums oder Schwarmelements ist die Gleichartigkeit im Hinblick auf die Artgenossen. Allerdings kann man an schwarmbildenden Tieren auch erkennen, dass eine 100%-ige Gleichartigkeit nicht notwendig ist. Ein Tier mit einem Handicap, wird allerdings dem Takt eines Schwarms nicht folgen können. In der Produktion technischer Systeme kann nicht immer eine ausreichende Gleichartigkeit sichergestellt werden. Daher muss per Design eine Kalibrierfähigkeit vorgesehen werden und es müssen dazu Spezifikationen erstellt werden, so dass in einem der Produktion folgenden Kalibrierschritt bzw. in gewissen zeitlichen Intervallen danach die Gleichartigkeit bis auf eine Restunsicherheit eingestellt werden kann.

Bei den im OK Lab verwendeten Sensoren vom Typ SDS011 wird werksseitig eine Kalibrierung durchgeführt und die Kalibrierdaten im Speicher des internen Mikrocontrollers abgelegt. Allerdings wurde von einigen Besitzern von Sensoren beklagt, dass ihre Sensoren zu arg von den Nachbarn abweichen würden, die eigentlich den gleichen Bedingungen ausgesetzt wären. Bisherige Untersuchungen ergaben allerdings, dass nur gewisse alte Versionen abweichende Werte ergeben.

Um daher eine zu starke Unterschiedlichkeit auszuschließen wurden stichprobenhaft einige Sensoren ausgewählt und auf gleiches Verhalten hin geprüft.

Dazu wurde ein Referenzsensor als „Golden Device“ ausgewählt und sowohl der Prüfling wie der Referenzsensor mit einem auf dem Arduino-Mikrocontroller basierten Datenlogger verbunden. Anschließend wurden beide Sensormodule in einem Testvolumen von 20 Litern (Kunststoffbox mit dichtem Deckel) untergebracht. In einem Testraum, in dem das Testvolumen aufgestellt war, wurde dann mit Hilfe eines Rauchmelder-Testsprays (Isopropanol-Aerosol) eine zunehmende Aerosol-Konzentration erzeugt, bis ein Handmessgerät eine PM10 Feinstaub-Konzentration von etwa $1\text{mg}/\text{m}^3$ anzeigte (obere Anzeigegrenze des Sensormoduls). Danach wurde das Testvolumen mit dem Deckel gasdicht verschlossen und der Testraum wieder gelüftet. Durch Sedimentation, Verdunstung und Anlagerung des Aerosols an den Wänden sinkt die Aerosolkonzentration nahezu exponentiell ab und durchläuft dabei den gesamten möglichen Werte-Bereich der Sensoren. Ein Vergleich beider Messkurven zeigt dann die Gleichheit in der Messfähigkeit des Prüflings zum Referenzsensor. Bei allen bisher untersuchten Sensoren (3 Stück der Version V2-008) wurde eine extrem gute Übereinstimmung festgestellt. In der logarithmischen Darstellung unterschieden sich die Sensoren im Mittel um weniger als 1dB.

Darüber hinaus gibt es in der Fachliteratur einige Studien hinsichtlich der Güte von Low-Cost Feinstaubsensoren, die weitestgehend zu dem Schluss kommen, dass die Genauigkeit gegenüber Profigeräten erstaunlich gut ist und den Einsatz als Consumer-Überwachungsgerät für gesundheitsrelevante Belange rechtfertigen. Dies legte die Annahme nahe, dass zumindest die Sensormodule der derzeit verbauten Version des SDS011 eine sehr ausgeprägte Gleichheit in der Messfähigkeit aufweisen und damit die werksseitige Kalibrierung so gut ist, dass eine schwarmbasierte Sicht auf die Messkurven möglich ist.




Abb. 2a: Direkter Messkurvenvergleich von Prüfling und Referenzsensor




Abb. 2b: Logarithmierte Werte der Messkurven von Prüfling und Referenzsensor , man erkennt eine leichte Abweichung von einem exponentiellen Abfall, aber beide Kurven laufen in sehr guter Übereinstimmung




Abb. 2c: Darstellung des Verhältnisses der Messkurven in Dezibel und einer mit linearer Regression gefitteten Trendlinie, die Fehlerstreuung nimmt mit abnehmenden Konzentrationswerten zu aber der mittlere Trend liegt bei einer Abweichung < 1dB

Das schwarmbasierte Auswerteverfahren

Datenreduktion

Die Daten aller Sensoren treffen im Minutenraster auf dem Server des OK Lab ein. Das bedeutet, dass für einen Sensor pro Tag ca. 20000 Datensätze abgespeichert werden. Ein Datensatz umfasst unter anderem den Zeitstempel des Servers sowie die PM10 und PM2.5 Werte, welche der Sensor für den Messzyklus von einer Minute erfasst und übertragen hat. Um die Daten für eine Feinstaub-Episode, die durchaus mehrere Wochen dauern kann, sinnvoll und ökonomisch auswerten und darstellen zu können, müssen die Daten massiv in der Menge reduziert werden. Die Änderung der Feinstaubkonzentration kann sich bedingt durch meteorologische Einflüsse wie z.B. Wind und Regen zwar innerhalb von Minuten massiv ändern, doch ist die Darstellung mit minutengenauer

Zeitauflösung selten notwendig. Im Hinblick auf eine Aussage, die eine ca. zweiwöchige Episode betreffen soll, erscheint eine zeitliche Auflösung von 1 Stunde eher sinnvoll. Daher wurde der Untersuchung hier ein Zeitraster mit Intervallen von 1 Stunde zugrunde gelegt und nur Messwerte für PM10 ausgewertet. Insgesamt war das Ziel, mindestens 10 Sensoren an unterschiedlichen Aufstellungsorten im Stuttgarter Stadtgebiet auszuwerten, so dass auch von einem Schwarm gesprochen werden kann.

Glättung und Interpolation

Bedingt durch die nicht miteinander synchronisierten Takte der Mikrocontroller in den Sensoren sowie unterschiedlichen Latenzzeiten bei der Übertragung über das Internet und der lastabhängigen Antwortzeit des Servers, weichen die Zeitstempel in den abgespeicherten Datensätze von dem etwa ein-minütigen Zeitraster eines einzelnen Sensors ab. Die Untersuchung einiger Datensätze ergab aber, dass der Jitter (Zeitvariation um das Zeitraster) im Bereich von wenigen Minuten liegt. Daher kann man davon ausgehen, dass dieser Jitter nach einer Mittelung über eine Stunde keine Rolle mehr spielt und die Daten zeitlich nicht verzerrt erscheinen.




Abb. 3a: Stark streuende Rohdaten auf unregelmäßigem Zeitraster mit fehlenden Werten




Abb. 3b: Geglättete Daten (blau) und auf ein regelmäßiges Raster interpolierte Daten, wobei fehlende Daten durch Wiederholung des letzten Werts gestopft werden (rot)

Als Mittelungsverfahren bietet sich wegen seiner Einfachheit ein gleitender Mittelwert mit einem Zeitfenster von 1h an. Auch wenn der Sendetakt nicht ganz genau einer Minute entspricht, wurde

hier davon ausgegangen, dass 60 Messwerte für ein Zeitfenster von 1h stehen. Daher wurde der gleitende Mittelwert für die letzten 60 Messwerte berechnet und dem aktuellen Zeitstempel zugeordnet.

Damit entstehen aber immer noch so viele gemittelte Werte wie Datensätze vorhanden sind, nur dass diese jetzt entsprechend geglättet sind. Um nun zu einer Datenreduktion zu kommen, muss entweder selektiert oder interpoliert werden. Da bei einigen Sensoren auf Grund von Übertragungsfehlern oder anderen Problemen auch immer wieder Datenlücken entstehen und die Zeitstempel wegen des Jitters nicht identisch sind, erschien das Selektieren, zum Beispiel eines jeden 60sten Messwerts, immer noch problematisch. Die Interpolation dagegen löst das Problem elegant, da hier ein äquidistantes Zeitraster vorgegeben werden kann, für dessen Werte zwischen den vorhandenen Messdaten interpoliert wird. Datenlöcher wurden dabei nach einem „1st order Hold“-Verfahren gestopft, das heißt der letzte gültige Datenwert wurde solange im ein-minütigen Takt wiederholt, bis ein neuer gültiger Wert auftauchte. Um den Rechenaufwand klein zu halten, wurde nach dem eventuellen Stopfen von Datenlöchern lediglich eine lineare Interpolation durchgeführt.

Eine umgekehrte Reihenfolge, bei der zuerst die Datenlöcher gestopft und interpoliert wird und dann gemittelt wird, verhält sich ungünstiger, da die Rohdaten doch sehr stark rauschen und man unter Umständen durch Wiederholung von Rauschspitzen sehr ungünstig stopfen würde.




Abb. 4: Reale Sensordaten (blau) sowie geglättete und interpolierte Daten (rot) am Anfang einer Episode (Sensor 143)




Abb. 5: Reale Sensordaten (blau) sowie geglättete und interpolierte Daten (rot) für die ganze 14-tägige Episode im Februar (Sensor 576), nach 17000 Minuten sieht man deutlich die horizontal eingefügten Daten für den kurzen Sensoraussetzer

Da das OK Lab die Daten eines Sensors tageweise archiviert, müssen nun die Daten eines jeden Sensors für alle Tage der zu analysierenden Episode eingelesen und wie oben beschrieben nachbearbeitet werden. Das Ausgabe-Format ist wieder ein csv-Format, das sich für die weitere Auswertung in Excel einlesen lässt. In der Ausgabe-Datei stehen nun die interpolierten PM10-Werte für das äquidistante Zeitraster. Um dieses festzulegen, muss bei der Ausführung für den ersten Sensor der Befehl `defineXi = 1` in Zeile 9 gesetzt werden, damit das Zeitraster in die Datei `xiFile.txt` geschrieben wird (siehe Skript im Anhang). Für alle weiteren Sensoren wird `defineXi = 0` gesetzt. Das hat zur Folge, dass für diese Sensoren das Zeitraster zur Interpolation aus der Datei „`xiFile.txt`“ eingelesen und verwendet wird. Auf diese Weise erhält man für alle Sensoren interpolierte PM10 Daten zu den selben Zeitpunkten und es ist sichergestellt, dass für jeden Sensor gleich viele (Zeitpunkt/PM10-Wert)-Paare entstehen.

Korrelation und Ausreißer-Detektierung

Ein kaum zu vermeidender Nachteil des Sensor-Paten-Konzepts des OK Lab ist, dass nicht sichergestellt ist, dass Paten ihre Sensoren ordnungsgemäß betreiben. Ein ordnungsgemäßer Betrieb setzt voraus, dass der Sensor sinnvoll und ortsfest außerhalb der Wohnung aufgestellt wird und Tag und Nacht eine Verbindung zu einem WLAN-Router besteht. Es gibt daher auch Fälle, wo der Sensor in der Wohnung betrieben oder an verschiedene Orte verfrachtet wird und mal hier und mal dort gemessen oder anderweitig experimentiert wird. Es ist auch möglich, dass ein Sensor ohne Zutun seines Paten nicht ordnungsgemäß funktioniert. Daher ist es vor der Auswertung notwendig, dass man versucht zu erkennen, ob die Daten plausibel sind oder ob Daten vorliegen, die völlig daneben liegen (Ausreißer). Da die Orientierung eines Schwarm-Individuums an seinem Nachbarn ein wesentlicher Wesenszug eines Schwarms ist, lässt sich eine einfache Plausibilitätsprüfung durch Berechnung der Korrelationskoeffizienten zu den Nachbarn erreichen. Liegt keine gute Korrelation vor, handelt es sich entweder nicht um einen Schwarm (dann sind die meisten Kurven untereinander

unkorreliert) oder es handelt es sich um einen einzelnen Ausreißer vom Schwarm bzw. um un plausible Daten (dann sind nur die Daten des einzelnen betrachteten Sensors zu den Nachbarn unkorreliert, die Nachbarn sind aber untereinander gut korreliert). Grundsätzlich empfiehlt sich die Definition eines Schwarmzentrums, d.h. die Auswahl weniger Sensoren oder eines Sensors, die als Referenz dienen und zu denen die Korrelation berechnet wird. Das spart den Rechenaufwand um Jeden gegen Jeden vergleichen zu müssen. Voraussetzung für die Referenzen ist eine sehr hohe Übereinstimmung der Kurvensignatur(en) und eine Glaubhaftigkeit hinsichtlich der lokalen meteorologischen und geografischen Verhältnisse. Günstig ist es auch einen Sensor als Referenz zu nehmen, der besonders hohe Werte liefert, damit später ein quantitativer Vergleich nur Werte in besserer Richtung liefert.




Abb. 6: Rohdaten der Sensoren in Nähe der Kreuzung "am Neckartor" für die Episode im Januar, der Sensor 143 wurde als Referenz definiert, dieser Sensor und seine gut korrelierten Nachbarn bilden das Schwarmzentrum

Bei dieser Untersuchung im Stuttgarter Stadtgebiet wurden durch visuelle Prüfung der Kurvenverläufe der Sensoren um die Neckartor-Kreuzung (143, 217 und 227) der Sensor mit der Nummer 143 als Referenz ausgewählt. Er weist für die untersuchten Episoden lückenlose Daten auf, hat einen angemessen glatten Kurvenverlauf und passt in seiner Signatur zu den Kurvenverläufen vieler Nachbarsensoren und bleibt dabei quantitativ bei den höchsten Werten. Damit vereinfacht sich die Berechnung der Korrelationskoeffizienten insofern, als dass ein zu beurteilender Sensor nur zu dieser Referenz auf Korrelation hin betrachtet werden muss. Eine gute Korrelation einer betrachteten Sensor Kurve zu dieser Referenz liegt vor, wenn der Korrelationskoeffizient besser als 0.9 beträgt. Eine schlechte Korrelation liegt dann vor, wenn der Korrelationskoeffizient weniger als 0.8 beträgt. Zu berechnen ist jeweils der Korrelationskoeffizient r nach Bravais und Pearson:

$$r = \frac{Cov(X, X_{ref})}{\sqrt{Var(X) * Var(X_{ref})}}$$

Hierin sind X die Werte des zu beurteilenden Sensors und X_{ref} die der Referenz, Cov ist die Kovarianz und Var die Varianz. In Excel steht die Funktion `Korrel()` (deutsch) bzw. `Correl` (englisch) zur Berechnung von r fest eingebaut zur Verfügung.

Als anschauliches Beispiel für die Berechnung der Korrelationskoeffizienten sie hier ein Schwarm von Messkurven gezeigt, die aus von Rauschen überlagerten Sinusfunktionen erzeugt wurden. Die dritte Messkurve von unten weicht signifikant vom Schwarmverhalten (eine volle Sinusperiode) ab und bewegt sich mit vierfacher Frequenz. Dies zeigt sich massiv bei der Berechnung der Korrelationskoeffizienten der Kurvenverläufe zur obersten Kurve, die als Referenz benutzt wurde. Hier sinkt der Korrelationskoeffizient gegenüber normalen Werten von besser als 0.8 auf einen Wert nahe Null ab.

Eine weitere Prüfung auf das Vorliegen eines Ausreißers ist möglich, wenn der mittlere quadratische Fehler (root-mean-square-Fehler, RMS-Fehler) zu einem Scharmittelwert oder einer Referenz berechnet wird. Während der Korrelationskoeffizient unabhängig von einer Skalierung der Kurve gegen die Referenz ist, reagiert der RMS-Fehler auch schon auf eine reine Skalierung oder den Offset der Kurve. Daher ist es zweckmäßig vor der Anwendung des RMS-Fehlers zur Ausreißer-Detektion die Kurve so zu skalieren, dass der RMS-Fehler minimal wird und erst dann die verbleibenden RMS-Fehler untereinander zu vergleichen. Weicht ein Sensor sehr stark von den RMS-Fehlern der anderen Sensoren in der Schar ab, muss ebenfalls das Vorliegen eines Ausreißers angenommen werden. Der RMS-Fehler berechnet sich zu:

$$RMS = \sqrt{\frac{1}{N} \sum_{i=1}^N (X(i) - X_{ref}(i))^2}$$

Wobei über alle Werte i des Sensors und der jeweiligen Referenz in einer Episode aufsummiert wird.




Abb. 7a: künstlich erzeugte Schwarmkurven mit einem Ausreißer (vierfache Frequenz)

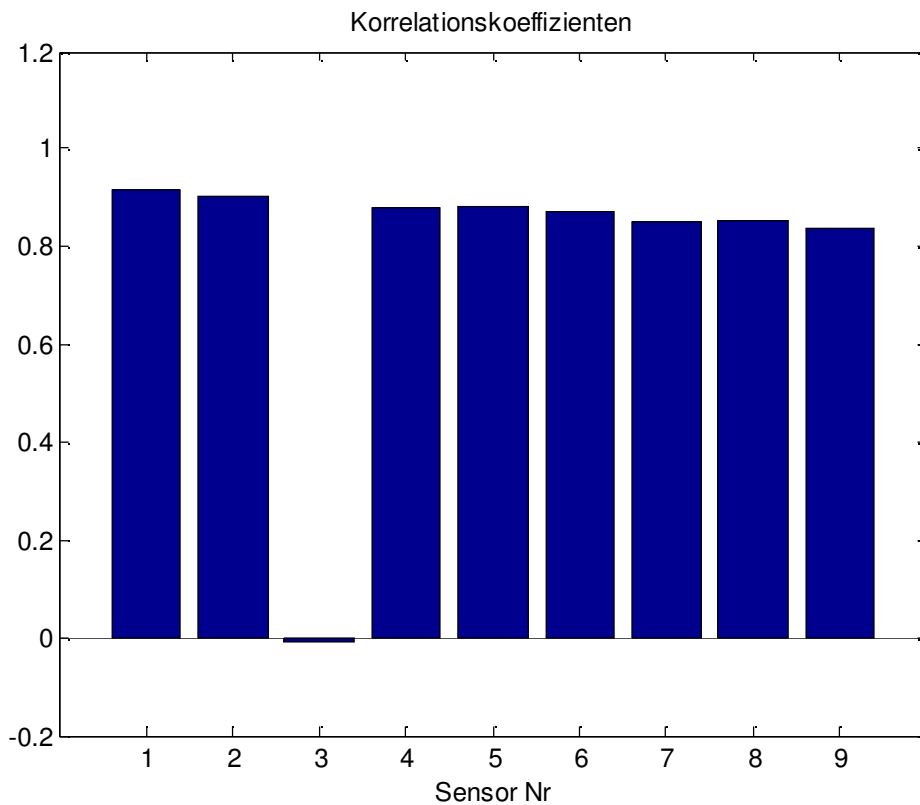


Abb. 7b: Zur obersten Kurve in a) berechnete Korrelationskoeffizienten, deutlich ist der Ausreißer an der fehlenden Korrelation erkennbar

Dies sei hier ebenfalls an künstlich erzeugten Schwarmkurven gezeigt. Hier liegen 5 Kurvenverläufe nahe beieinander, bei der mittleren Kurve jedoch tauchen auf Grund eines simulierten Fehlers für gewisse Zeit Nullwerte auf, wo das jeweilige Schwarmelement sich nicht im Gleichtakt mit den anderen bewegt. Nimmt man als Referenz wieder die oberste Kurve an, sieht man zunächst durchaus einen RMS-Fehler, der von Null verschieden ist, der aber dennoch gering ist. Im Falle der ersten zwei Kurven taucht jedoch ein deutlich von Null verschiedener Wert auf. Dieses Verhalten liegt daran, dass der Offset der Kurven anders als beim Korrelationskoeffizient bereits zu einem RMS-Fehler führt. Allerdings führen die Nullwerte in der Messkurve im Falle des 3-ten Schwarmelements dann doch zu einem deutlich sichtbaren Ansteigen des RMS-Fehlers, an dem der Ausreißer eindeutig erkannt werden kann.

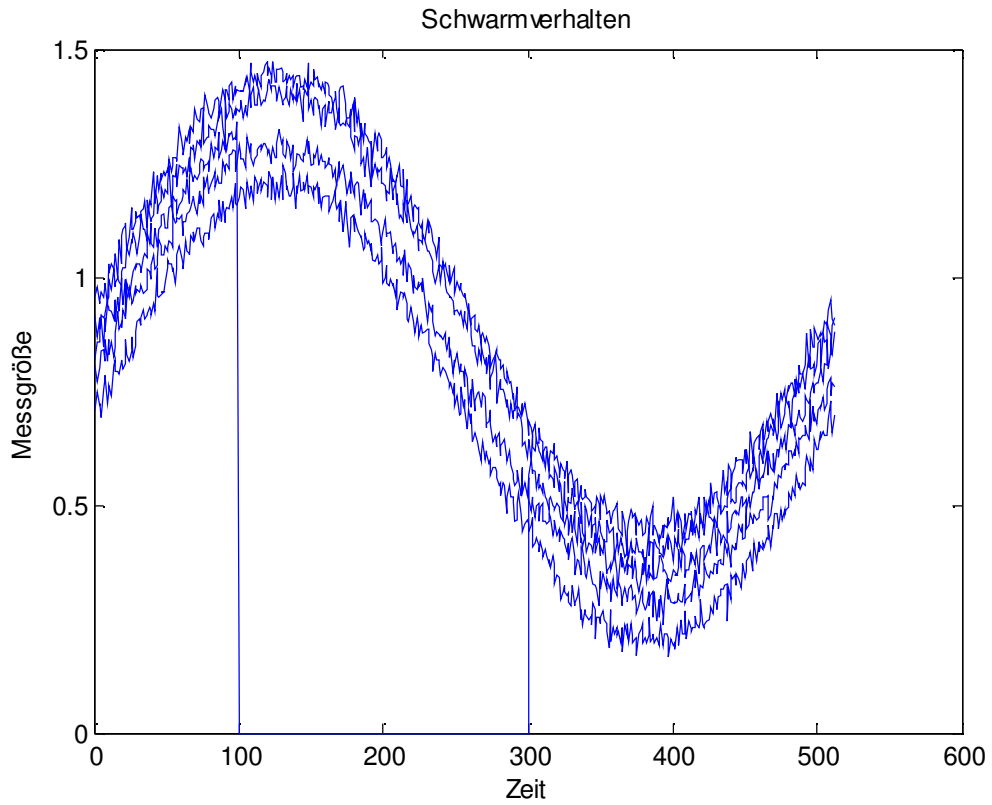


Abb. 8a: künstlich erzeugte Schwarmkurven mit einem Ausreißer (temporäre Nullwerte)

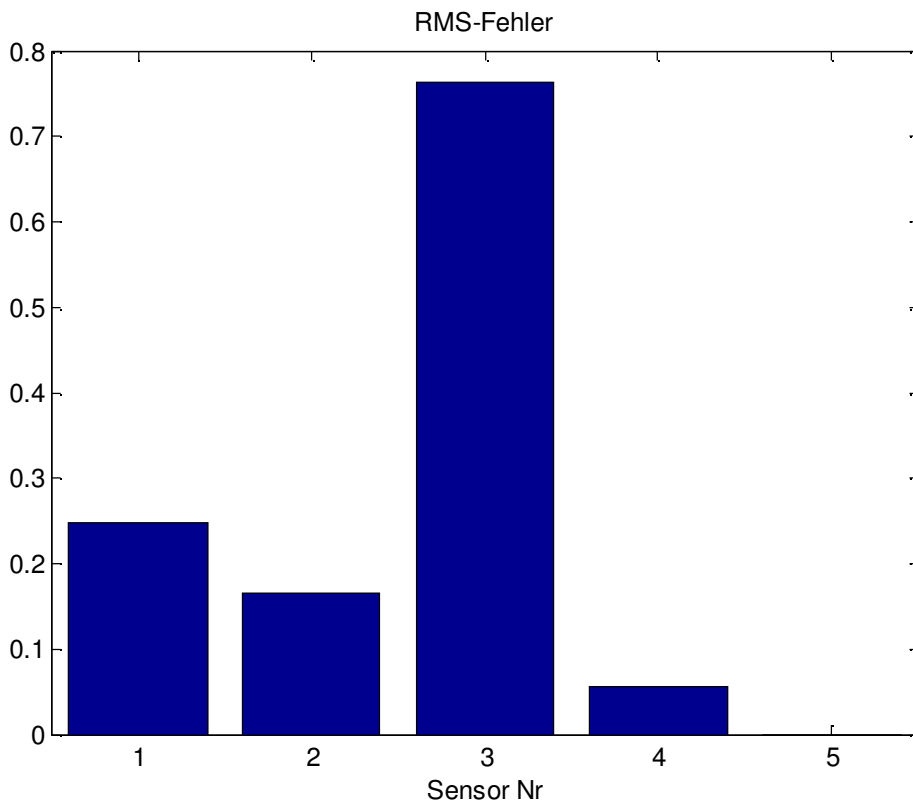


Abb. 8b: Zur obersten Kurve in a) berechneter RMS-Fehler, deutlich ist der Ausreißer am erhöhten Fehlerwert erkennbar

Fitting Methoden

Bei der Untersuchung der Kurvenverläufe der Sensoren im Stadtgebiet zeigt sich schnell, dass die meisten Sensoren während einer Episode sehr gut zueinander korreliert sind und in erster Größenordnung lediglich ein quantitativer Unterschied in Form eines Skalierungsfaktors vorliegt. Der von einem Skalierungsfaktor unabhängige Korrelationskoeffizient nimmt für viele der Sensoren im Stadtgebiet von Stuttgart während der untersuchten Feinstaubepisoden Werte von besser als 0.9 an. Das äußert sich auch darin, dass sich eine Kurve eines Sensors zu einer im Sinne des kleinsten Fehlerquadrats sehr guten Übereinstimmung mit der Referenzkurve bringen lässt, wenn man sie lediglich mit einem konstanten Fitting-Faktor (Skalierungsfaktor) multipliziert. Der Fitting-Faktor kann dabei iterativ minimiert werden.

D.h. es gilt dann für den Skalierungs- oder Fitting-Faktor a :

$$X_{ref} \sim a * X \quad \text{mit} \quad RMS_{\min}(a) = \min \sum_i (a' * X_i^2 - X_{ref}^2) \quad \text{für} \quad a' \in \mathbb{R}^+$$

wobei das Tilde-Symbol hier die Ähnlichkeit (im Gegensatz zur vollkommenen Gleichheit) ausdrücken soll, die nach dem Minimieren im Sinne des kleinsten Fehlerquadrats erreicht wird.




Abb. 9: Skalierte Messkurven im Vergleich zur Schwarmreferenz, selbst der Sensor 140 im Stuttgarter Westen kann zu einer guten Übereinstimmung mit der Referenz gebracht werden, wenn er mit dem Skalierungsfaktor $a=1.7$ multipliziert wird

Eine andere Möglichkeit, die keine Iteration erfordert, wurde von Norbert Streibl angegeben. Diese Methode basiert auf der Erkenntnis, dass die Verteilung der PM10 Werte während einer Feinstaub-Episode mit guter Näherung einer Log-Normalverteilung folgt. Logarithmiert man daher die Werte eines Sensors und die der jeweiligen Referenz, dann erhält man Zufallsvariable, welche annähernd normalverteilt sind. Nun ist eine Normalverteilung vollständig über ihre beiden ersten Momente μ und σ definiert, wobei die Streuung σ die Breite der Verteilung bestimmt und μ die Lage der Verteilung vorgibt. Daher kann durch Verschiebung auf den gleichen Mittelwert und durch

Skalierung auf die gleiche Streuung durch eine einfache lineare Operation auf die durch Logarithmieren auf Normalverteilungen transformierten Log-Normal-Verteilungen eine Übereinstimmung in μ und σ zur definierten Referenz erreicht werden. Diese in μ und σ übereinstimmenden Kurven weisen auch in ihren Werten eine recht gute Übereinstimmung auf. Führt man danach wieder für jeden Sensor eine Rücktransformation auf eine Log-Normalverteilung aus, erhält man gefittete Kurven, die eine gute Übereinstimmung mit der Referenz zeigen. Die Parameter, die zur Anpassung verwendet wurden, lassen sich bei der Rücktransformation in einen Faktor k und einen Exponenten e einer Potenzfunktion überführen, welche nun die endgültigen Fitting-Parameter darstellen. Meist zeigt sich, dass bei guter Korrelation der Exponent e gegen 1 geht, so dass k gegen den Skalierungsfaktor a strebt. Daher werden bei beiden Verfahren sehr ähnliche Übereinstimmungen erreicht.

Die logarithmierten Werte Y und Y_{ref} werden aus den Rohdaten X und X_{ref} mit Hilfe eines Bezugswertes von $X_0 = 50\mu\text{g}/\text{m}^3$ berechnet:

$$Y = 10 * \log_{10}\left(\frac{X}{X_0}\right)$$

und

$$Y_{ref} = 10 * \log_{10}\left(\frac{X_{ref}}{X_0}\right)$$

Die Mittelwerte μ und μ_{ref} sowie die Streuungen σ und σ_{ref} dieser logarithmierten Werte werden nun benutzt um die Normalverteilung von Y auf die Referenz anzupassen. Das angepasste Ergebnis ist \tilde{Y} :

$$\tilde{Y} = (Y - \mu) * \frac{\sigma_{ref}}{\sigma} + \mu_{ref}$$

Anschließend wird die angepasste Normalverteilung wieder zurücktransformiert:

$$Y' = 50 * 10^{\frac{\tilde{Y}}{10}}$$

Man kann nun Y' durch Einsetzen und Umformen in eine Potenzfunktion überführen:

$$Y' = k * X^e$$

$$\text{mit } k = 50 * \left(\frac{1}{50}\right)^{\frac{\sigma_{ref}}{\sigma}} * 10^{\frac{-\mu_{ref} + \mu_{ref}}{10}}$$

$$\text{und } e = \frac{\sigma_{ref}}{\sigma}$$

und damit Y' auch direkt berechnen.

Der Vorteil dieses Verfahrens besteht hauptsächlich darin, dass hier keine Iteration zur Berechnung des minimalen RMS-Fehlers nötig ist.




Abb. 10: Die Fitting-Parameter während der Episode im Januar im Vergleich, der reine Skalierungsfaktor a ist bis auf den Fall des Ausreißers 189 fast identisch zum Parameter k in Norbert Streibls Verfahren




Abb. 11: Berechnet man den RMS-Fehler zu den mit k und e nach Norbert Streibls Verfahren gefitteten Kurven, dann ergibt sich ein fast identisches Ergebnis zum Fitting mit dem Skalierungsfaktor a alleine (siehe Episode im Januar)

Schwarmkenngrößen

Unter einem Schwarm (oder auch Ensemble oder Schar) von Messkurven wird hier speziell eine Kurvenschar verstanden, die von Sensoren geliefert wird, welche die Feinstaubkonzentration in einer Region unter annähernd den gleichen meteorologischen Bedingungen über die Zeitdauer einer Feinstaub-Episode gemessen haben. Sie sind damit nachbarschaftlich gekoppelt. Wenn nun das Zeitraster für alle betrachteten Sensoren identisch ist, dann können statistische Parameter, wie Mittelwert, Median, Streuung, Minimalwert und Maximalwert auch über den Schwarm (oder das Ensemble) hinweg, und nicht wie sonst üblich über die Zeit hinweg, gebildet werden. Das heißt, dass die jeweiligen statistischen Parameter über alle Messkurven für jeden einzelnen Zeitpunkt des Zeitrasters berechnet werden. Auf diese Weise kommt man zu den Schwarmgrößen wie Schwarmmittelwert oder Schwarmstreuung, welche dann zur Beschreibung der Eigenschaften eines Schwarms benutzt werden können. Dies sei hier an einem Beispiel einer künstlich erzeugten Kurvenschar aus verrauschten Sinusfunktionen beschrieben.

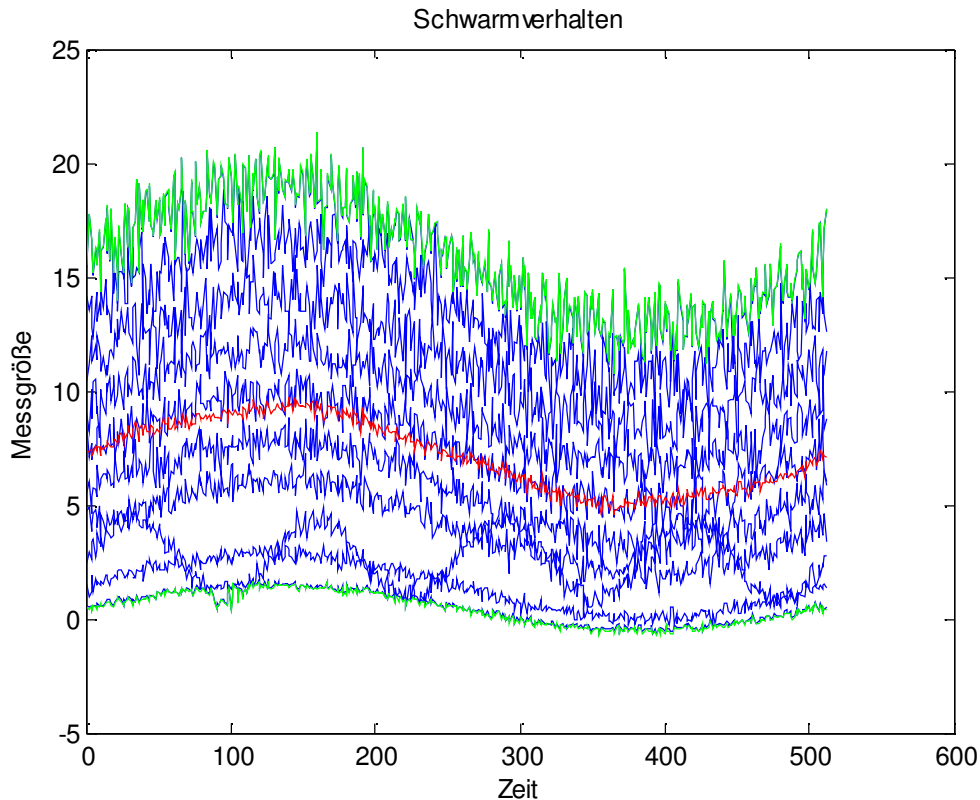


Abb. 12: Künstlich erzeugte Schwarmkurven (blau) sowie Schwarmmittelwert (rot) und Schwarm-Minimum und Schwarm-Maximum (grün)

Dieser Schwarm wird von Sinuskurven mit einer Periodendauer gebildet, die zusätzlich verrauscht (Normalverteilung) und mit einem Offset versehen sind. Der normale Mittelwert über eine Periode einer Kurve wäre identisch mit ihrem Offset. Der Schwarmmittelwert jedoch, der für jeden Punkt auf dem Zeitraster in x-Richtung über den Schwarm hinweg berechnet wird und hier als rote Kurve dargestellt ist, ist eine Zeitfunktion und ebenfalls eine (verrauschte) Sinusfunktion, die den sinusförmigen „Gleichtakt“ bzw. die einheitliche Bewegung des Schwarms repräsentiert, ungeachtet des Ausreißers in Form der zweituntersten Kurve.

Genauso folgen die Schwarm-Minimum und Schwarm-Maximum-Werte (in grün dargestellt) den Schwarmrändern. Die zweitunterste Kurve lenkt stärker aus als die unterste Kurve, daher unterschreiten ihre Werte auch die der Kurve mit dem kleinsten Offset. Deswegen folgt der Schwarm-Minimumwert auch den extremen Auslenkungen der zweituntersten Kurve. Der Abstand zwischen der Schwarm-Minimum- und -Maximumkurve definiert die Schwarmbreite an jeder Stelle des Zeitrasters (hier in x-Richtung). In ganz vergleichbarer Weise kann man eine rein statistische Schwarmbreite mit den Funktionen $\mu_s \pm \sigma_s$ im Falle von ganz zufälligen Sensorsignalen (stochastischen Prozessen) definieren, wenn μ_s der Schwarmmittelwert und σ_s die Schwarmstreuung ist.

Schwarmbasierter Luftgüte-Index

Die wesentliche Erkenntnis dieser Untersuchung ist nun, dass der Skalierungsfaktor a (und ganz vergleichbar der Parameter k bei $e \approx 1$) eine zentrale Bedeutung für die Bewertung der Feinstaub-bezogenen Luftgüte zu haben scheint. Man erkennt schnell, dass etliche Kurven von gut korrelierten Sensoren mit sehr guter Übereinstimmung aufeinander zu liegen kommen, wenn der Skalierungsfaktor so gewählt wird, dass der RMS-Fehler minimal wird. Unter der Annahme, dass die Sensoren unter gleichen (Kalibrier-)Bedingungen gleiche Werte liefern, bedeutet das, dass alle Sensoren im Stadtgebiet, annähernd die selbe Signatur tragen, die im Wesentlichen durch die

Meteorologie während der Episode bestimmt wird. Während starker Feinstaub-Episoden mit Inversionswetterlage liegen oft Hochdruckgebiete mit windarmen stabilen Wetterbedingungen bis in große Höhen vor. Daher bewegt sich der Schwarm der Messkurven praktisch im Gleichtakt, aber eben skaliert um einen Faktor, den man nun als Luftgüte bezüglich des Feinstaubes für einen bestimmten Aufstellungsort und eine betrachtete Episode interpretieren kann. Er sagt aus um welchen Faktor die Werte eines Sensors multipliziert werden müssen um die Werte des Schwarmzentrums zu erreichen. Wenn nun das Schwarmzentrum so gewählt wird, dass dort die höchsten Werte im untersuchten Gebiet gemessen werden, also in Stuttgart am Neckartor, dann ist dieser Skalierungsfaktor ein Maß, das angibt um wieviel besser die Luftqualität am Aufstellungsort eines Sensors ist, im Vergleich zum Schwarmzentrum am Neckartor. Der Skalierungsfaktor a wird somit zum Feinstaub-bezogenen Luftgütefaktor. Es wird sich auch zeigen, dass diese Luftgütefaktoren über mehrere Episoden ganz ähnlich aussehen, man kann daher auch Mittelwerte über die Faktoren mehrerer Episoden bilden und somit den Wert für einen Aufstellungsort unabhängig von einzelnen Episoden angeben.

Die Feinstaub-Episode im Januar 2017

Von 15.1.-30.1.2017 ergab sich bedingt durch extreme Wetterverhältnisse in ganz Süddeutschland eine besonders intensive Feinstaub-Episode. Nach Mitteleuropa eingeströmte polare Kaltluft geriet unter starken Hochdruckeinfluss. Im Laufe mehrerer aufeinander folgender Hochs kühlte die Bodenoberfläche weiter aus und die Temperaturen fielen bis unter -10°C . Langsam schob sich Warmluft über die Kaltluft und die winterbedingte flache Sonneneinstrahlung konnte nur die obersten Luftschichten weiter erwärmen. Auf diese Weise bildete sich eine ausgedehnte Inversionsschicht, wobei die Temperaturen in 1000m Höhe um mehrere Grad höher lagen als am Boden. In dieser Zeit herrschte bei den stabilen Luftdruckverhältnissen auch nahezu Windstille. Die Temperaturverteilung stoppte den vertikalen konvektionsbedingten Luftaustausch, so dass sich Abgase durch Verkehr, Heizungen und Industrieanlagen in den bodennahen Luftschichten besonders stark aufkonzentrierten.

Am 23.1. erreichte die morgendliche, bodennahe relative Feuchte auch noch Werte nahe 100%, so dass sich zusätzlich Nebel bildete, der zusammen mit den Abgasen in der Luft einen deutlich sichtbaren braunen Smog bildete. An diesem Tag registrierten die OK Lab Messstationen Messwerte von teilweise über $400\mu\text{g}/\text{m}^3$ in der Feinstaubklasse PM₁₀. Die amtliche Messstation erreichte an diesem Tag den Höchstwert der Episode mit Werten um $180\mu\text{g}/\text{m}^3$ für den gleitenden Mittelwert über 24h.

Die ausgedehnten stabilen Wetterverhältnisse sorgten ebenfalls dafür, dass sich die Feinstaubkonzentrations-Unterschiede in der Region leicht ausgleichen konnten, so dass praktisch alle Sensoren des OK Lab Netzwerks im Stuttgarter Stadtgebiet und darüber hinaus sehr vergleichbare Bedingungen hatten und damit auch gut korrelierte Daten lieferten.

Für die Auswertung wurden zunächst Sensoren im Stadtgebiet ausgewählt, die während der Episode kontinuierlich Daten geliefert hatten. Um eine weitere Selektion hinsichtlich der Plausibilität der Daten vorzunehmen, wurde der Korrelationskoeffizient der Messkurven zur Schwarmreferenz mit den bekanntlich höchsten Werten am Neckartor berechnet (Sensor 143). Unter den im Stadtgebiet ausgewählten 18 Sensoren ergaben sich für alle bis auf einen Sensor Korrelationskoeffizienten von besser als 0.95. Lediglich ein Sensor (Nr. 189) lag bei 0.6.

Durch Vergleich gut korrelierter und skaliertes Messkurven mit der Kurve des Sensors 189 wurde schnell klar, dass dieser Sensor nur bis zum 26.1.2017 teil des Schwarms war. Danach war er offensichtlich für eine gewisse Zeit anderen Aerosol-Einflüssen ausgesetzt.




Abb. 13: Der Korrelationskoeffizient der Messkurven aller untersuchter Sensoren zur Referenz für die Episode im Januar, der Korrelationskoeffizient identifiziert den Sensor 189 eindeutig als Ausreißer




Abb. 14: Referenz und guter Sensor 140 (skaliert mit Faktor 1.7) im Vergleich zum Sensor 189 der ganz offensichtlich ab dem 26.1. nicht mehr die Signatur der Stuttgarter Episode trägt

Im nächsten Schritt wurde der Skalierungsfaktor a so gewählt, dass der RMS-Fehler zur Schwarmreferenz minimal wurde und es wurde der verbleibende RMS-Fehler über der Zeit aufgetragen. Man kann schnell erkennen, dass auch der RMS-Fehler deutlich auf die unplausiblen Daten des Sensors 189 reagiert. Man kann ebenfalls erkennen, dass tendenziell von der Referenz entferntere Sensoren einen größeren verbleibenden RMS-Fehler aufweisen. Die Sensoren im Stadtzentrum liegen aber alle sehr ähnlich und zeigen einen RMS-Fehler zum Neckartor-Sensor von etwa $10\text{-}25\mu\text{g}/\text{m}^3$.




Abb. 15: Beispiel der RMS-Rechnung zur Detektierung von Ausreißern vom Schwarmzentrum für die Episode im Januar, auch hier fällt der Sensor 189 mit einem unnatürlich RMS-Fehler gegenüber dem Schwarmzentrum auf

Trägt man nun gute und nicht ganz so gut korrelierte, skalierte Messurven gemeinsam in einem Graphen auf, so stellt man fest, dass der Mangel an Korrelation hauptsächlich durch starke Spikes bzw. durch größere Datenlöcher, die bei der Interpolation gestopft wurden bedingt sind.




Abb. 16: Überlagerung der Messkurven der gut korrelierten Sensoren nach der Skalierung im Januar, einzelne Sensoren weisen Peaks bzw. größere gestopfte Datenlöcher auf




Abb. 17: Überlagerung der Messkurven der gut korrelierten Sensoren nach der Skalierung im Januar, alle Kurven zeigen hervorragende Übereinstimmung

Dagegen zeigen 14 sehr gut korrelierte Sensoren im Stadtgebiet nach der Skalierung einen fast perfektes Schwarmverhalten mit sehr guter Übereinstimmung der skalierten Messkurven. Das aber bedeutet, dass diese Sensoren sich im völligen Gleichtakt bewegt haben und der Schwarm eine ausgeprägte „Kohäsion“ hatte.

Berechnet man Schwarmmittelwert und Schwarmstreuung über Zeit, dann erhält man ein sehr enges Band in dem die Schwarmbewegung verläuft. Die maximale Schwarmstreuung beträgt nur etwa 17% des Maximalwerts der Messwerte und trat zum Zeitpunkt des Peaks auf.

Die Tatsache, dass lediglich der Skalierungsfaktor für quantitative Unterschiede sorgte, lässt vermuten, dass die Signatur der Schwarmbewegung vorwiegend von den global wirksamen Wetterbedingungen herrührt und die Unterschiede in den Skalierungsfaktoren tatsächlich die verbleibenden Unterschiede in der Feinstaub-Luftgüte am Aufstellungsort beschreiben. Hierbei ist allerdings unterstellt, dass die Sensoren alle über gute werkseitig eingestellte Kalibrierdaten verfügten und keine Unterschiede durch unterschiedliche Sensorempfindlichkeit entstanden.




Abb. 18: Schwarmmittelwert und Schwarmstreuung in $\mu\text{g}/\text{m}^3$ um den Schwarmmittelwert über die gut korrelierten Sensoren im Februar

Sensor	r	a	scaled err	rms
217	0.99	0.9	17.6	
237	0.98	0.9	19.4	
143	1.00	1	0.0	
221	0.98	1	20.5	
227	0.98	1.1	20.2	
191	0.98	1.2	19.3	
241	1.00	1.2	10.5	
151	0.98	1.3	23.7	
164	0.99	1.3	17.7	
295	0.96	1.3	31.8	
309	0.98	1.3	22.5	
286	0.98	1.4	24.1	
187	0.99	1.6	17.5	
219	0.98	1.6	22.1	
140	0.99	1.7	14.7	
291	0.99	2.7	16.1	
422	0.96	2.9	30.3	

Tabelle 1: Nach Größe sortierter und farblich codierter Skalierungsfaktor a für die Episode im Januar

Nun wurde von der Feinstaub-Karte zu einem Zeitpunkt mit niedriger Belastung (alle Sensoren durch grüne Waben dargestellt) ein Screenshot angefertigt, die Sensorkartennummer mit den

Skalierungsfaktoren eingetragen und mit einem nach einer Farbskala codierter Kreis unterlegt. Auf diese Weise erkennt man, dass es sich beim Skalierungsfaktor a in der Tat um ein Maß für die Feinstaub-Luftgüte handeln könnte. Tendenziell weisen die Sensoren nahe des Neckartors Werte nahe 1 auf (gleiches Werte-Niveau) während Sensoren mit größerem geographischen Abstand zu Werten zwischen 1.5 und 3 tendieren. In dieser Karte sind Sensoren die nicht ausgewertet wurden mit grauen Zahlen dargestellt und solche, die wegen unplausibler Daten verworfen wurden mit einem zusätzlichen dünnen schwarzen Kreis versehen.

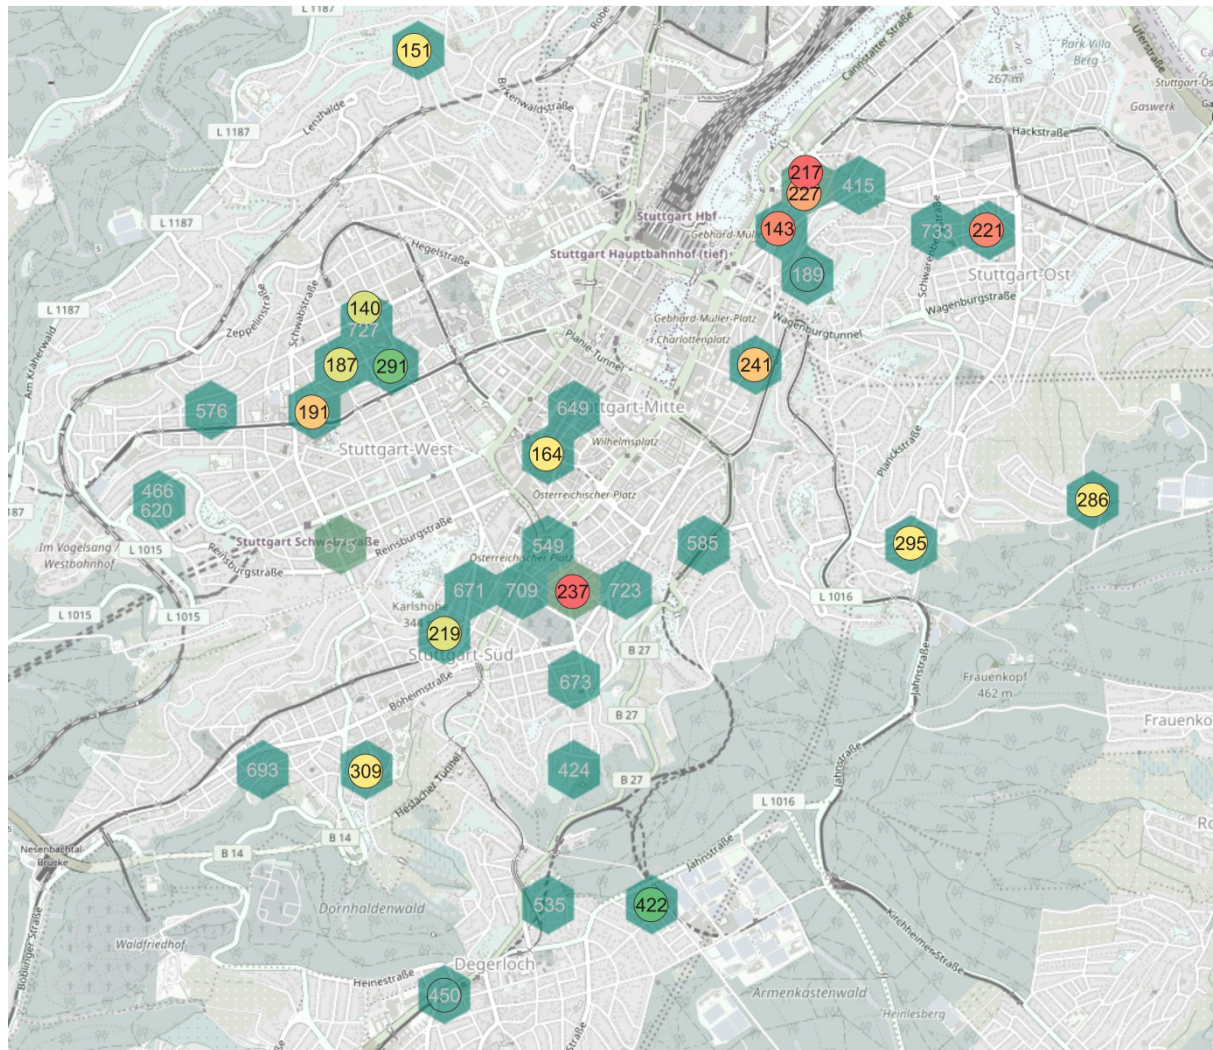


Abb. 19: Kartendarstellung der Skalierungsfaktoren a für die Sensoren im Stadtgebiet für die Episode im Januar (Quelle Kartendaten: luftdaten.info, OK Lab Stuttgart)

Insgesamt lässt sich aber über die Kartendarstellung auch erkennen, dass während dieser Episode im Januar zwar am Neckartor die höchsten Werte gemessen wurden, der Gradient zu niedrigeren Feinstaub-Konzentrationen Richtung Stadtzentrum hin nicht besonders stark war. Man kann also davon ausgehen, dass die Feinstaub-Konzentrationen sich über der Zeit der Episode gut ausgleichen konnten und das besondere verkehrsbedingte Quell-Verhalten am Neckartor keine dominante Auswirkung hatte.

Die Episode im Februar 2017

Von 5.2. bis 18.2.2017 Februar trat erneut eine deutliche Feinstaub-Episode auf. Auch sie war durch eine Inversionswetterlage gekennzeichnet, aber diese war regional nicht so stark ausgedehnt wie im Januar. Auch die Temperaturen waren im Februar nicht so tief wie im Januar. Dementsprechend wurden in der Hochphase von den OK Lab Sensoren am Neckartor zwar hohe Werte von etwa $200\mu\text{g}/\text{m}^3$ registriert, sie lagen aber deutlich unter den Werten im Januar.

Auch hier wurde wieder der Korrelationskoeffizient genutzt um Sensoren mit unplausiblen Daten zu eliminieren. Als Schwarmzentrum und Referenz wurde wieder der Sensor mit der Nummer 143 am Neckartor gewählt.




Abb. 20: Der Korrelationskoeffizient der Messkurven aller untersuchter Sensoren zur Referenz für die Episode im Februar

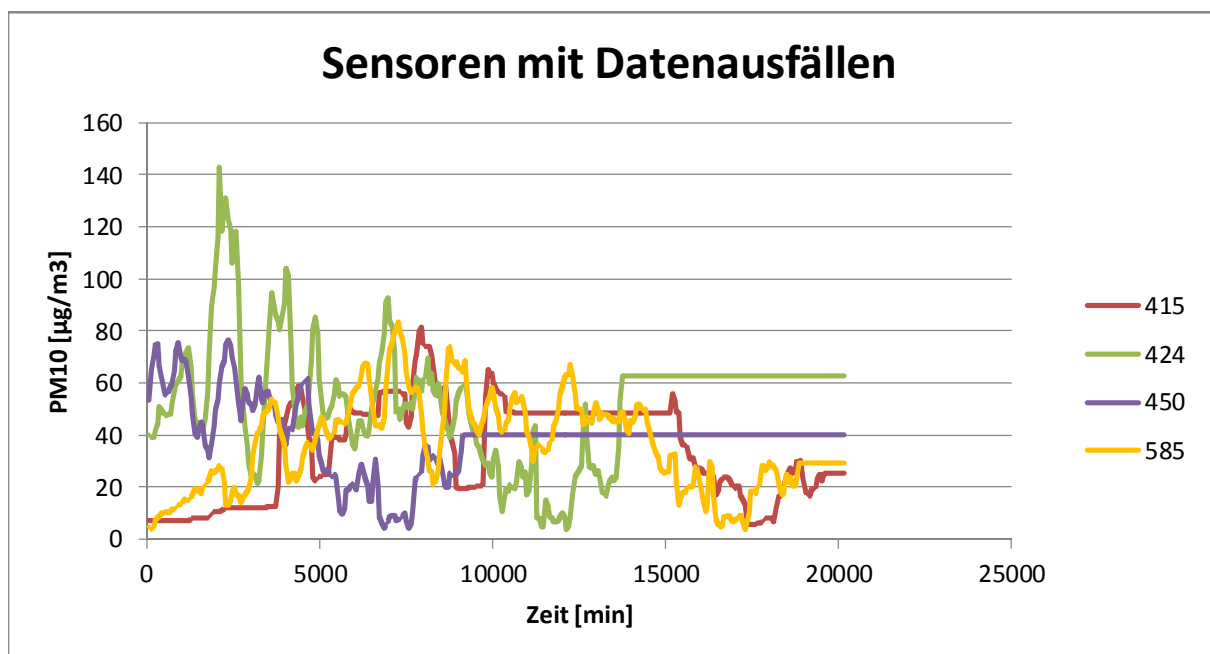


Abb. 21: Beispiele für Sensoren mit schlechter Korrelation infolge von großen „Datenlöchern“ im Februar

Während dieser Episode war das Fehlen von Daten ein vorherrschender Grund für fehlende Korrelation, allerdings traten teilweise auch abweichende Signaturen bzw. einzelne starke Peaks auf,

die zu Korrelationsproblemen führten. Dennoch lagen die gut korrelierten Sensoren auch wieder bei Korrelationskoeffizienten von besser 0.95 und die weniger gut korrelierten bei Werten besser als 0.9. Lang andauernde Datenaussetzer führten dagegen sogar zu negativen Werten in der Korrelation.

Die RMS-Fehler nach der Minimierung mit Hilfe des Skalierungsfaktors α zeigten keine großen Auffälligkeiten auch nicht bei den Sensoren mit kleineren Datenausfällen. Das liegt hauptsächlich daran, dass kleinere Datenausfälle, die nicht im Bereich dramatischer Werteänderungen liegen, durch das Stopfen nach der Glättung sowie der darauffolgenden Interpolation durchaus noch zu verwertbaren Kurven führen können. Daher lagen die verbleibenden RMS-Fehler im Bereich unter $80\mu\text{g}/\text{m}^3$ und damit noch auf einem akzeptablen Niveau.




Abb. 22: Der RMS-Restfehler (in $\mu\text{g}/\text{m}^3$) aller ausgewerteter Sensoren im Februar




Abb. 23: Überlagerung der Messkurven der gut korrelierten Sensoren mit geringen Skalierungsfaktoren α im Februar, die Skalierungsfaktoren sind in der Legende angegeben

Legt man die gut korrelierten Messkurven nach der Minimierung des RMS-Fehlers mit dem Skalierungsfaktor α aufeinander, dann sieht man wieder, dass ein sehr kohärentes Schwarmverhalten der Sensoren vorlag. Das Streuband um den Mittelwert betrug im schlimmsten Fall nur 15% vom Maximalwert ($207\mu\text{g}/\text{m}^3$), nämlich $31\mu\text{g}/\text{m}^3$.

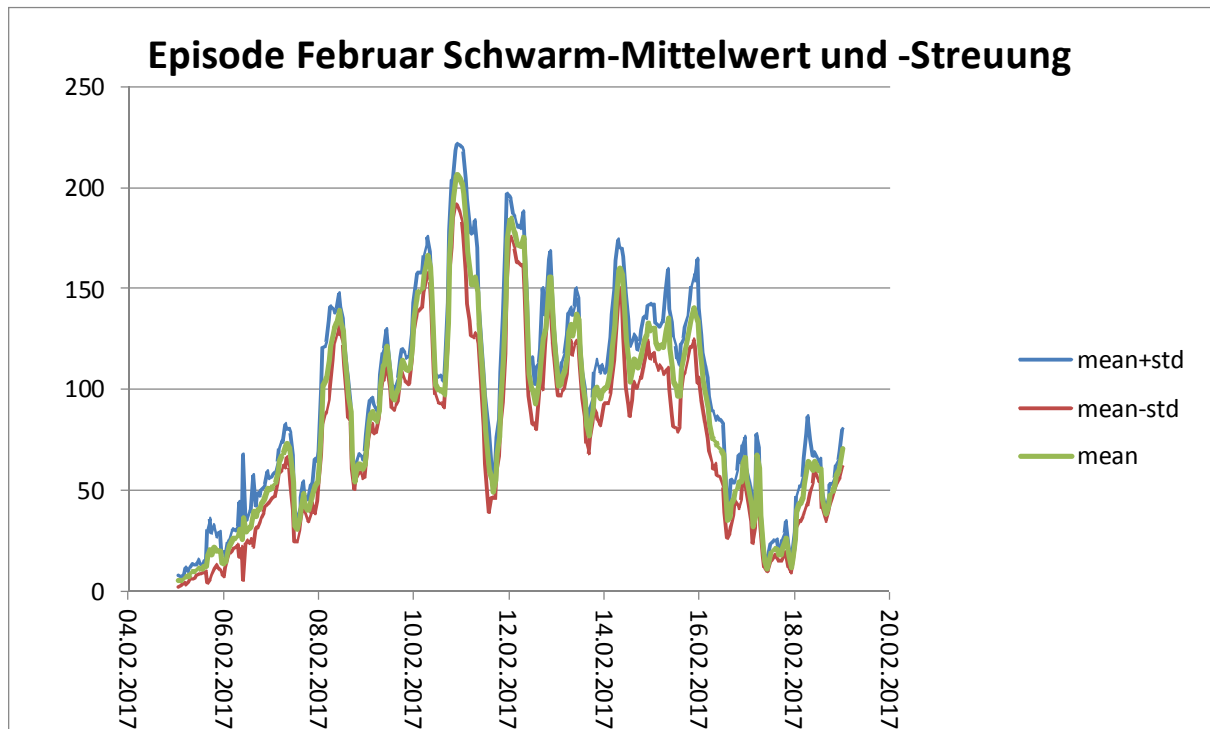


Abb. 24: Schwarmmittelwert und Schwarmstreuung um den Schwarmmittelwert über die gut korrelierten Sensoren im Februar

Sensor	r	a	scaled rms err
143	1.000	1	0
217	0.989	1	9
221	0.906	1	23
237	0.968	1	13
151	0.975	1.2	12
227	0.967	1.2	13
286	0.934	1.2	20
309	0.968	1.2	13
535	0.932	1.2	20
164	0.970	1.3	13
191	0.973	1.3	12
466	0.975	1.3	12
576	0.983	1.3	10
189	0.960	1.4	15
241	0.992	1.4	7
295	0.957	1.4	15
219	0.968	1.6	13
187	0.985	1.7	9
140	0.983	1.8	9
291	0.984	2.4	9
422	0.957	2.7	15

Tabelle 2: Nach Größe sortierter und farblich codierter Skalierungsfaktor a für die Episode im Februar

In der Karte der Sensor-Aufstellungsorte im Stadtgebiet ergibt sich für die Episode im Februar ein erstaunlich ähnliches Bild wie während der Episode im Januar. Trägt man die nötigen Skalierungsfaktoren a in die Karte ein, tauchen ebenfalls Werte nahe 1 um die Kreuzung am Neckartor auf, die nur wenig in Richtung Stadtzentrum abnehmen. In größerer Entfernung erreichen diese Faktoren, die man als Feinstaub-Luftgütefaktoren interpretieren könnte, Werte zwischen 1.5 und 2.7 .

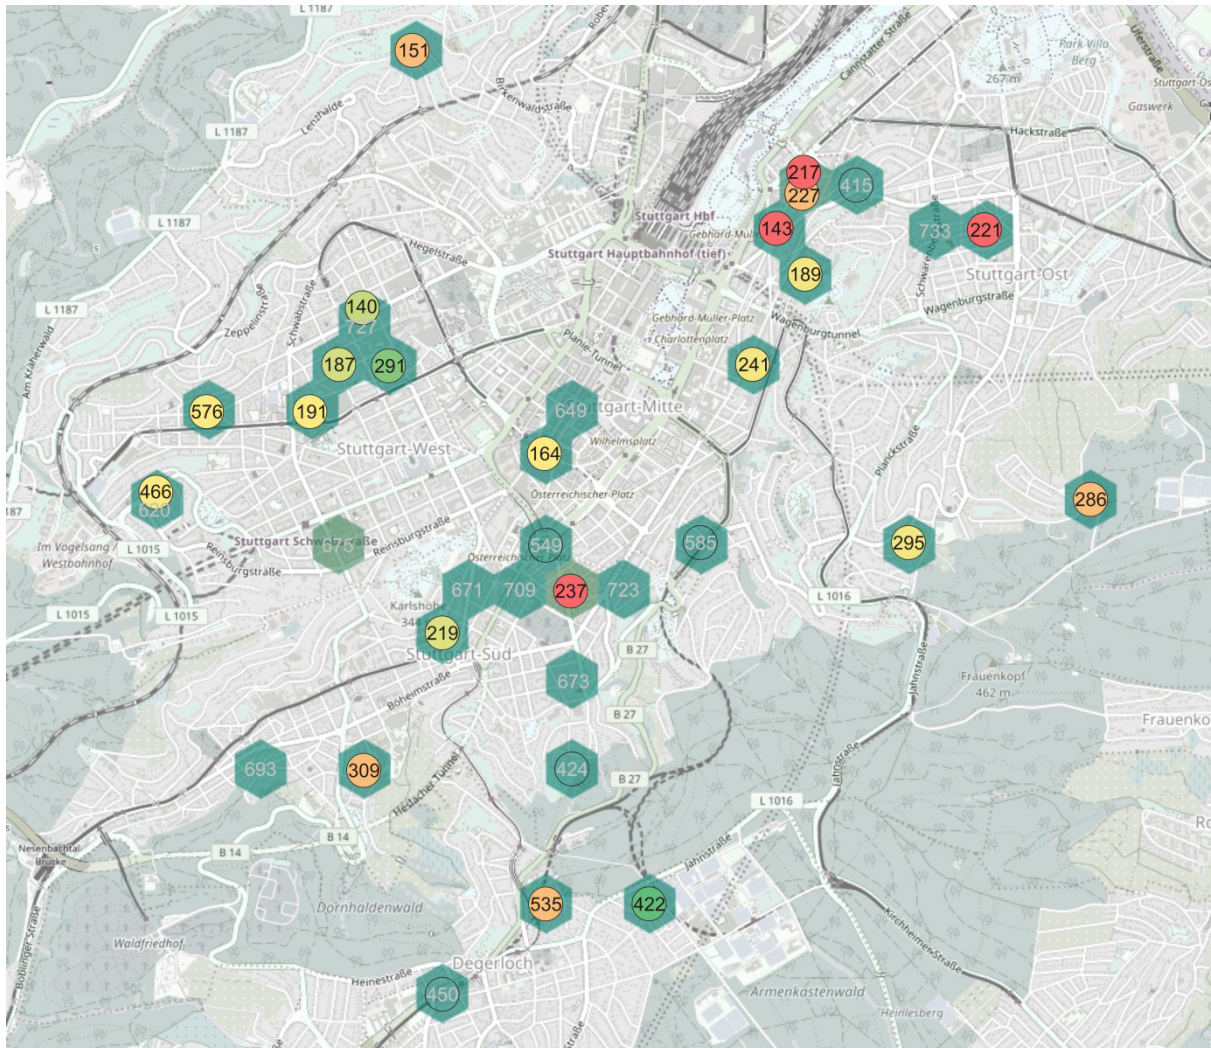


Abb. 25: Kartendarstellung der Skalierungsfaktoren A für die Sensoren im Stadtgebiet für die Episode im Februar (Quelle Kartendaten: luftdaten.info, OK Lab Stuttgart)

Beim Vergleich der berechneten Skalierungsfaktoren während der beiden Episoden kann man zahlenmäßig lediglich einen Unterschied von 1% erkennen. Dies aber legt nahe, anzunehmen, dass diese Faktoren zwischen den deutlichen Feinstaub-Episoden mit stabilen meteorologischen Bedingungen gar nicht groß variieren werden, also annähernd unabhängig von der jeweiligen Episode sind. Dies unterstützt die Annahme der allgemeinen Verwendbarkeit dieser Skalierungszahl a als Feinstaub-Luftgüte-Index unter der Voraussetzung gut kalibrierter Sensoren.

	Episode 16.1.-30.1.17			Episode 5.2.-18.2.17			Differenz in a zw. den Episoden
Sensor	r	a	scaled rms err	r	a	scaled rms err	
140	0.99	1.7	15	0.983	1.8	9	-6%
143	1.00	1	0	1.000	1	0	0%
151	0.98	1.3	24	0.975	1.2	12	8%
164	0.99	1.3	18	0.970	1.3	13	0%
187	0.99	1.6	18	0.985	1.7	9	-6%
191	0.98	1.2	19	0.973	1.3	12	-8%
217	0.99	0.9	18	0.989	1	9	-11%
219	0.98	1.6	22	0.968	1.6	13	0%
221	0.98	1	21	0.906	1	23	0%
227	0.98	1.1	20	0.967	1.2	13	-9%
237	0.98	0.9	19	0.968	1	13	-11%
241	1.00	1.2	10	0.992	1.4	7	-15%
286	0.98	1.4	24	0.934	1.2	20	15%
291	0.99	2.7	16	0.984	2.4	9	12%
295	0.96	1.3	32	0.957	1.4	15	-7%
309	0.98	1.3	22	0.968	1.2	13	8%
422	0.96	2.9	30	0.957	2.7	15	7%
							Durchschnittliche Differenz
							-1%

Tabelle 3: Vergleich der Skalierungsfaktoren a in den beiden Episoden im Januar und Februar 2017

Vergleich zu amtlichen Messungen

Eine drängende Frage der interessierten Bevölkerung ist natürlich die nach der Übereinstimmung der Messergebnisse der OK Lab Sensoren mit den amtlichen Daten. Daher wurden auch die amtlichen Daten für die Episode im Januar gesammelt und in der gleichen Weise interpoliert, wie die Daten der OK Lab Sensoren. Aus den gut korrelierten OK Lab Sensoren am Neckartor (Nummer 143, 217 und 227) wurde ein Mittelwert berechnet und ebenfalls, so wie es die Stadt veröffentlicht, ein gleitender 24h Mittelwert gebildet.

Legt man nun die Kurven aufeinander, kann man zwei Dinge feststellen: Erstens liegen die Messwerte zum Zeitpunkt der höchsten Werte grob um einen Faktor 2 auseinander und zweitens ist die Korrelation der Kurvenverläufe schlecht. Da aber viele Sensoren des OK Lab einen sehr kohärenten Schwarm gebildet haben und nach der Skalierung praktisch im Gleichtakt dieselben Kurven gemessen haben, ist anzunehmen, dass es einen systematischen Unterschied in der Messtechnik gibt und nicht einen Defekt oder Fehlmessungen im statistischen Sinne.




Abb. 26: Vergleich der OK Lab Messkurven von Sensoren am Neckartor mit der Messkurve der amtlichen Messstation am Neckartor für die Episode im Januar

Nun ist es so, dass die eigentliche PM10-Messung, welche das Landesumweltamt in gerichtsfester Weise am Neckartor machen muss, eine gravimetrische Feinstaub-Messung nach genauer Vorschrift der EU ist. Bei dieser gravimetrischen Messung wird ein Filter, durch das die Luft 24 Stunden lang angesaugt wurde, für jeden Tag mit einer Präzisionswaage gewogen. Nachdem dies erst etliche Tage nach dem Filterwechsel im Labor geschieht, ist das Filter getrocknet und die Netto-Trockenmasse besteht lediglich aus der Masse der trockenen Feinstaubpartikel. Die Messung die zeitnah veröffentlicht wird ist jedoch eine Messung nach dem Laser-Streulicht-Verfahren, ganz vergleichbar wie bei den OK Lab Sensoren. Bei dem Laser-Streulichtverfahren aber wird ein feuchtes Aerosol genauso registriert wie ein trockenes Aerosol.




Abb. 27: Um einen Ultrafeinstaub-Partikel (UFP) kondensierende Feuchte, die Masse m und der Durchmesser wachsen dabei beträchtlich und bewirken eine Berücksichtigung in der Klasse PM10 oder PM2.5 beim Laser-Streulichtverfahren

Ultra-Feinstaub mit einem aerodynamischer Querschnitt $< 0.1\mu\text{m}$ trägt bei einer PM10 Messung der Massenkonzentration so gut wie nicht zum Ergebnis bei, obwohl er von den Partikelzahlen um Größenordnungen stärker auftritt als die größeren Partikel in der Größenklasse PM10. Das liegt an dem viel geringeren Gewicht der Ultra-Feinstaub-Partikel. Nun dienen aber die Ultra-Feinstaub-Partikel, die zahlenmäßig weit häufiger auftreten als Partikel zwischen 0.1 und $10\mu\text{m}$ vorwiegend als Kondensationskerne für die Kondensation von Feuchte. Unter dem Einfluss der Kondensation

Fazit

Es kann gezeigt werden, dass eine schwarmbasierte Auswertung der Sensoren im OK Lab Netzwerk, die sich an der guten Korrelation benachbarter Sensoren orientiert, zu sehr konsistenten Ergebnissen führt, die es möglich machen, eine Bewertung der Feinstaub-Luftgüte im Stadtgebiet vorzunehmen. Eine Bewertung muss sich dabei aber immer auf die Beurteilung benachbarter Sensoren stützen, deren Daten auf Plausibilität geprüft wurden, und nicht auf einzelne ungeprüfte Sensoren, da Fehler z.B. durch falsche Kalibrierdaten oder durch fehlerhaft aufgestellte Sensoren nicht völlig ausgeschlossen werden können.

Methoden wie die Berechnung der Korrelation der Messkurven im Schwarm relativ zur Schwarmreferenz oder die Berechnung des mittleren Fehlerquadrats kann sehr effizient dazu benutzt werden um Ausreißer zu identifizieren und die Plausibilität der Daten zu prüfen, bevor eine Beurteilung der Daten erfolgt. Auch die Berechnung anderer Schwarmparameter wie Schwarmmittelwert und Schwarmstreuung helfen bei der Beurteilung der Datenintegrität und erlauben eine detailliertere Klassifizierung einer Feinstaub-Episode.

Es konnte auch gezeigt werden, dass eine Glättung der Daten mit einem gleitenden Mittelwert über eine Stunde, sowie die darauffolgende Interpolation auf ein äquidistantes Zeitraster einerseits eine erhebliche Datenreduktion ermöglicht, die Konsistenz und Aussagekraft der Daten aber nur unwesentlich beeinflusst. Dabei hat es sich in einigen Fällen als vorteilhaft erwiesen, fehlende Daten mit vorangegangenen Werten zu ersetzen. Bei größeren Mengen an fehlenden Daten müssen die jeweiligen Messkurven jedoch verworfen werden, da die Korrelation stark beeinträchtigt werden kann, bzw. die Anpassbarkeit der Kurve an die Referenz nicht mehr vernünftig möglich ist.

Die Auswertemethode zeigt, dass wenn die Messkurven des Sensor-Schwarms gut korreliert sind, sie über eine einfache Skalierungsfunktion oder auch durch eine statistische Kurvenanpassung zur guten quantitativen Übereinstimmung an eine Schwarmreferenz gebracht werden können. Die Parameter zur Anpassung waren im Experiment über zwei unterschiedliche Episoden hinweg erstaunlich ähnlich und legen nahe, dass sie eine Episoden-unabhängige Gültigkeit haben. Die Anpassungsparameter (Fitting-Parameter), und im Falle einer einfachen Skalierung der Skalierungsfaktor, lässt sich daher mit großer Wahrscheinlichkeit auch als ein auf die Feinstaub-Belastung bezogener Luftgüte-Indikator verwenden. Damit wäre es dann möglich, auf dezentrale Messungen gestützte Aussagen auch über andere Stadtbezirke mit ausgeprägter Wohnbebauung zu machen und nicht nur Aussagen über wenige Spotmessungen an einzelnen stark befahrener Straßen.

Links und Literatur

OK Lab

Webseite des Feinstaub-Projekts im OK Lab Stuttgart
<http://luftdaten.info>

Schwarmintelligenz

/1/ Swarm Intelligence - Introduction

Thiemo Krink

EVAlife Group, Dept. of Computer Science, University of Aarhus

/2/ Schwarmverhalten

VR-Coralreef Project

Universität Bremen

<http://cgvr.cs.uni-bremen.de/teaching/studentprojects/vrcoralreef/files/Schwarmverhalten.pdf>

/3/ Swarm Intelligence

David Corne, Alan Reynolds and Eric Bonabeau

School of Mathematical & Computer Sciences, Heriot Watt University, Edinburgh, Scotland

/4/ Swarm Intelligence: A brief introduction

Andrea Roli, Dept. of Computer Science and Engineering (DISI)

Alma Mater Studiorum Universita di Bologna

/5/ OpenGL Swarm Intelligence-Tutorial von Daniel Schwamm

<http://www.daniel-schwamm.de>

/6/ Swarm intelligence

Yichen Hu

http://guava.physics.uiuc.edu/~nigel/courses/569/Essays_Fall2012/Files/Hu.pdf

Low-Cost Sensoren

/7/ Laboratory assessment of low-cost PM monitors

Abhisek Manikonda, Naděžda Zíková, PhilipK.Hopke, AndreaR.Ferro

Journal of Aerosol Science 102(2016)29–40

/8/ Using Low Cost Sensors to Measure Ambient Particulate Matter Concentrations and On-Road Emissions Factors

Karoline K. Johnson, Michael H. Bergin, Armistead G. Russell, Gayle S. W. Hagler

Atmos. Meas. Tech. Discuss., doi:10.5194/amt-2015-331, 2016

/9/ Calibration and Characterization of Low-Cost Fine Particulate Monitors and their Effect on Individual Empowerment

Michael D. Taylor

The Robotics Institute, Carnegie Mellon University, Pittsburgh Pennsylvania

/10/ Laboratory Evaluation and Calibration of Three Low-Cost Particle Sensors for Particulate Matter Measurement

Yang Wang, Jiayu Li, He Jing, Qiang Zhang, Jingkun Jiang & Pratim Biswas

Aerosol Science and Technology

Fitting Methode (private Korrespondenz mit Norbert Streibl)

/11/ Kalibriermethode für Feinstaubsensoren

Norbert Streibl, Januar 2017

/12/ Vergleich Tageswerte PM10

Norbert Streibl, Februar 2017

/13/ Kalibriermethode für Feinstaubsensoren

Norbert Streibl, Februar 2017

/14/ Formelsammlung zum Kalibrieren der OK-Lab Sensoren

Norbert Streibl, Februar 2017

Feinstaub-Themen (private Webseite opengeiger.de, Stichpunkt Feinstaub)

/15/ Ein Feinstaub-Messgerät auf Arduino-Basis für die Feinstaubklassen PM10, PM2.5 und PM1.0

Bernd Laquai, 23.12.2016, Update 30.12.16

/16/ Arduino-basierte Auswertung von Messdaten und Data-Logging für den Feinstaubsensor SDS011 von Nova Fitness
Bernd Laquai, 5.01.2017

/17/ Rauchmelder-Testsprays für den Funktionstest von Feinstaubsensoren
Bernd Laquai, 26.1.2017

/18/ Die Feinstaubepisode vom 16.1.-30.1.2017 und ihre Auswirkungen in Stuttgart
Bernd Laquai, Ewald Thoma, 9.2.2017

Anhang

Listing des Octave/Matlab-Skripts zur Glättung und Interpolation der Sensor-Rohdaten:

```
% read out one sensor, filter, stuff missing data and interpolate
% output whole episode data into one file
clear;
sensNr=221;
startDay = 16;
stopDay=16;
startMon = 2;
stopMon = 2;
defineXi = 1; % is one if this sensor defines the timing grid zero otherwise
T0 = datenum([2017 startMon startDay 0 0 0])*24*60; %start of episode
outname=sprintf('%d.csv', sensNr); %output file containing episode data for one sensor
outfid=fopen(outname, 'a');
tArrAll_x = []; % all time values of episode in absolute time
pm10ArrAll = [];
for mon = startMon:stopMon %loop over days of episode
    for day=startDay:stopDay
        url=sprintf('http://archive.luftdaten.info/2017-%02d-%02d/2017-%02d-
%02d_sds011_sensor_%d.csv', mon, day, mon, day, sensNr);
        fprintf('%s\n', url);
        fflush(1);
        [str, status]=urlread(url);
        if status % the file is available
            indat=strread(str, '%s', 'delimiter', '\n');
            nrLine=length(indat);
            tArr=zeros(1,nrLine-1); %time values of one day
            pm10Arr=zeros(1,nrLine-1); %pm10 values of one day
            for i=1:nrLine-1 %extract values from each dataset per line
                [sensId sensType loc lat lon timeSt PM10 dum1 dum2 PM2_5] =
                strread(indat[i+1], '%d%s%d%f%f%s%f%d%d%f', 'delimiter', ';');
                tArr(i) = datenum(datevec(timeSt{1}, 'yyyy-mm-ddTHH:MM:SS'))*24*60; % time stamp in
minutes
                pm10Arr(i) = PM10;
            end
            tArrAll_x = [tArrAll_x tArr]; %append data of one day
            pm10ArrAll = [pm10ArrAll pm10Arr];
        else
            fprintf('%s does not exist\n', outname);
        end
    end
end
tArrAll = tArrAll_x-T0; % all time values of episode relative to start time

%filtering
windowSize=60;
pm10ArrAll=filter(ones(1,windowSize)/windowSize,1,pm10ArrAll);
tArrAll=tArrAll(windowSize:end);
pm10ArrAll=pm10ArrAll(windowSize:end);
plot(tArrAll,pm10ArrAll,'-'); hold on; % plot filtered data in blue

if (defineXi) %calculate and store timing grid from first file into xiFile.txt
    dt = 60; %1 hour spacing (in minutes)
    xi = ceil(tArrAll(1)):dt:floor(tArrAll(end));
    xiFid = fopen('xiFile.txt', 'w');
```



```

    fprintf(xiFid, '%d ', xi); %print timing grid to console
    fclose(xiFid);
else %read in timing grid
    xiFid = fopen('xiFile.txt', 'r');
    xi = fscanf(xiFid, '%d ');
end

%pad missing data at start or end
x=tArrAll;
y=pm10ArrAll;
xleft = [];
xright = [];
yleft = [];
yright = [];
if (xi(1) < x(1))
    xleft = xi(1);
    yleft = y(1);
end
if (xi(end) > x(end))
    xright = xi(end);
    yright = y(end);
end
x = [xleft x xright];
y = [yleft y yright];

%interpolate data at timing grid points
yi=interp1(x,y,xi);
plot(xi,yi,'o-r'); hold off; %plot interpolated data in red

%print to console and into output file
fprintf('%d %d %d %d %d %d\n', datevec(T0/24/60)); %first line is absolute start time
fprintf(outfid, '%d %d %d %d %d %d\n', datevec(T0/24/60));
for i=1:length(xi)
    fprintf('%d ', xi(i));
    fprintf(outfid, '%d;%f\n', xi(i), yi(i)); %output relative tme and PM10 value
end
fprintf('\n');
fclose('all');

```