

# Erkennung von Anomalien und Veränderung in Graphsequenzen<sup>1</sup>

Daniele Zambon<sup>2</sup>

## Abstract:

Wir verzeichnen einen erheblichen Zuwachs an Daten, die von Sensornetzen und sozialen Netzwerken gesammelt werden, verursacht durch technologische Entwicklungen und die Verbreitung sozialer Plattformen. Die Auswertung dieser riesigen Datenströme ist eine wichtige Aufgabe für die Wissenschaft ebenso wie für die Industrie. Da Datenströme von Sensoren (sei es physischen oder virtuellen) in der Regel funktionale Abhängigkeiten aufweisen, erweisen sich Graphen als reichhaltige Strukturen, die in der Lage sind, sowohl Informationen auf der Ebene der Sensoren/Entitäten als auch die komplexen Beziehungen zwischen den Entitäten zu modellieren. Diese graphbasierte Repräsentation wiederum ermöglicht uns, mittels Graph Neural Networks und Geometric Deep Learning, Inferenzen in Bezug auf Graphsequenzen anzustellen. Im Allgemeinen gehen solche Verarbeitungsverfahren allerdings von der Hypothese der Stationarität aus, die nicht immer gegeben ist, z.B. wenn eine Alterung der Sensoren, eine zeitliche Varianz oder eine Veränderungen in den Präferenzen der Nutzer auf sozialen Plattformen vorliegt. In dieser Dissertation befassen wir uns mit dem Problem der Identifizierung von Veränderungen der Stationarität, die durch unbekannte Phänomene im zugrundeliegenden Datenerzeugungsprozess verursacht werden und sich in der Sequenz der Graphen zeigen. Die wissenschaftlichen Ergebnisse erlauben es uns, auch das Problem der Erkennung von Anomalien zu behandeln, das in der Tat eine wertvolle Fortsetzung der Forschung darstellt. Wir betrachten eine allgemeine Familie von mit Attributen versehenen Graphen mit nicht-identifizierten Knoten, um ein möglichst breites Spektrum von Anwendungen abzudecken. Der Hauptbeitrag dieser Arbeit besteht in einer Methodik zur Verarbeitung einer Sequenz von Graphen, um unerwartete Ereignisse (Änderungen der Stationaritäten und/oder Auftreten von Anomalien) im Datenerzeugungsprozess zu erkennen. Die Methodik beruht auf der Entwicklung neuartiger Embeddings auf Graphenebene und Methoden zur Erkennung von Veränderungen, die durch ein solides theoretischen Grundgerüst unterstützt werden.

## 1 Einleitung

Immer mehr Daten stehen zur Verfügung, die von Monitoringinstanzen und Einzelpersonen gesammelt werden; die Daten stammen aus dem Internet der Dinge, den Neurowissenschaften und der Teilchenphysik, sowie aus Empfehlungssystemen und sozialen Netzwerken [AT05; BS16; JM15; Ra18], um nur einige datenerzeugende Anwendungen zu nennen.

---

<sup>1</sup> Englischer Titel der Dissertation: "Anomaly and Change Detection in Sequences of Graphs"

<sup>2</sup> Università della Svizzera italiana, Faculty of Informatics, Via Buffi 13, 6900 Lugano, Switzerland daniele.zambon@usi.ch

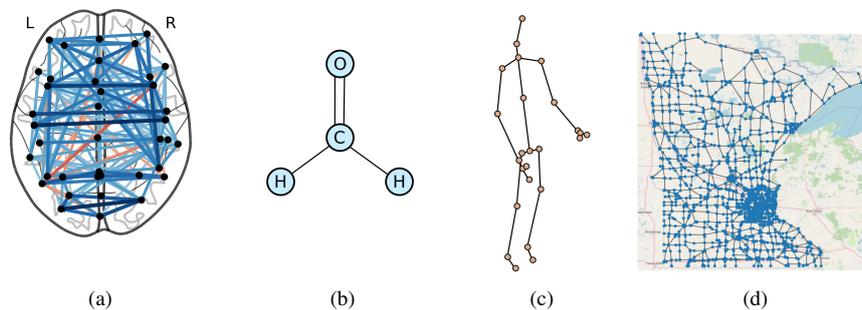


Abb. 1: Beispiele für graphbasierte Repräsentationen. Tafel 1a) Mit der Pearson-Korrelation berechnetes Netzwerk funktioneller Konnektivität. Tafel 1b) Molekulargraph der Formaldehydverbindung. Tafel 1c) Skelettgraph eines Menschen. Tafel 1d) Graph der Hauptstraßen im Bundesstaat Minnesota.

Da Datenströme häufig zeitliche und funktionale Abhängigkeiten aufweisen, widmet die Forschung immer mehr Aufmerksamkeit den Inferenzmethoden, die bestehende Beziehungen ausnutzen. Innerhalb dieser Forschungslinie werden Daten effektiv als Graphen dargestellt, wie es natürlicherweise in Molekülen und Proteinen der Fall ist, wo Atome (oder Substrukturen) durch Bindungen vernetzt sind. [Bo05; Li16; Yo18], oder in Sensornetzwerken, wo erfasste Signale eine funktionale Abhängigkeit aufzeigen können [ANR13]. Andere Beispiele, bei denen eine Graphdarstellung nahe liegt, sind soziale Netzwerke, Smart Grids und körperbasierte Netzwerke [BS16; CML11; MH19; Po16; YXL18]. Graphdarstellungen ermöglichen ein relationales induktives Bias [Ba18; Mi80], das den Werkzeugen maschinellen Lernens ermöglicht, Vorwissen und bestehende Einschränkungen direkt während der Lernphase zu nutzen, indem sie z.B. das Vorhandensein einer Netzwerkstruktur ausnutzen [Li18].

In der Graphenmodellierung können funktionale Abhängigkeiten als ein einfaches skalares Gewicht beschrieben werden, das jeder Kante zugeordnet ist, die funktional verwandte Knoten verbindet, was zu Graphen mit Knoten und/oder Kanten führt, die mit Attributen versehen sind. Allgemeiner ausgedrückt, sind Attribute Kennzeichnungen oder Merkmale in Form von Skalaren, Vektoren, Klassenmitgliedschaften und benutzerdefinierten Datenstrukturen. Darüber hinaus können mehrere Attribute mit demselben Knoten oder derselben Kante assoziiert sein. Die Definition von mit Attributen versehenen Graphen deckt eine breite Familie von Graphen ab, zu der u. a. gerichtete und ungerichtete gelabelte Graphen mit einer variable Anzahl von Knoten und Kanten gehören. In Abbildung 1 sind einige Beispiele für mit Attributen versehenen Graphen dargestellt, bei denen die Graphenstruktur a priori bekannt ist oder direkt aus den Daten geschätzt wird, e.g. aus Pearson-Korrelationen, die in einer multivariaten Zeitreihe gemessen wurden.

In Szenarien, die lebenslange Datenströme erzeugen, wie die von cyber-physischen Systemen, kann die überwachte Umgebung in der Tat zeitlichen Verschiebungen in der Datenverteilung unterliegen, die z.B. durch saisonale Schwankungen, Alterung von Sensoren und zeitliche

Varianz der Interaktion zwischen der Umgebung und dem Datenerfassungssystem verursacht werden. Die Hypothese der Stationarität des datenerzeugenden Prozesses, die oft bei vielen Aufgaben des maschinellen Lernens angenommen wird, ist nicht unbedingt allgemein gültig, und wir müssen entweder ihre Gültigkeit im Verlauf der Zeit überwachen oder mit Mitigationsstrategien in die Machine-Learning Lösung eingreifen, um den veränderten Betriebsbedingungen Rechnung zu tragen. Der letztgenannte Fall wird als Lernen in nicht-stationären Umgebungen bezeichnet, und Anpassungsmechanismen sind einfache Beispiele für Mitigationsstrategien [Di15].

Beim Lernen in nicht-stationären Umgebungen unterscheiden wir zwischen passiven adaptiven Methoden, die sich kontinuierlich anpassen, sobald neue Daten beobachtet werden [EP11; LP17], und pro-aktiven Methoden, welche die Machine-Learning Modelle nur dann neu konfigurieren, wenn eine Änderung der Stationarität erkannt wird [ABR13; BG07]. Die Erkennung von *Änderungen der Stationarität* des datenerzeugenden Prozesses ermöglicht es uns zu ermitteln, wann das aktuelle Modell nicht mehr aktuell ist und seine (Hyper-)Parameter entweder aktualisiert oder sogar das gesamte Modell neu konfiguriert werden muss. Veränderungen der Stationarität treten in verschiedenen Formen auf. Eine abrupte Änderung der Stationarität bezeichnet beispielsweise einen Wechsel von einem stationären Zustand zu einem neuen - anderen - stationären Zustand [BN+93]. In anderen Fällen handelt es sich um ein vorübergehendes Verhalten, bei dem der Prozess von einem stationären Zustand zu einem anderen wechselt, bevor er wieder in seinen ursprünglichen Zustand zurückkehrt. Drifttypen von Veränderungen der Stationarität beziehen sich stattdessen auf langsame Übergänge des datenerzeugenden Prozesses [Ga14]. Ein Problem im Zusammenhang mit der Erkennung vorübergehender Veränderungen ist die Erkennung von Anomalien, die sich auf die Identifizierung von Transienten bezieht, die durch (fast) augenblickliche Ereignisse gekennzeichnet sind [Pi14]. Darüber hinaus kann es bei Graphen zu Ereignissen kommen, die Knoten, Kanten oder ganze Teilgraphen betreffen. Andere Arten von Veränderungen haben einen globalen Einfluss oder können nicht auf bestimmte Teile des Graphen zurückgeführt werden [ATK15; Ra15].

Methoden zur Erkennung von Anomalien und Veränderungen in Graphdaten ermöglichen nicht nur eine Modellanpassung, sondern bieten auch spezielle Werkzeuge zur Untersuchung physikalischer Phänomene, z.B. zur Überprüfung des baulichen Zustands eines Gebäudes [SCF00], zur Identifizierung von Fehlern in großen cyber-physischen Systemen [ANR16] oder zur Analyse der elektrische Aktivität im Gehirn, um über internes Funktionsverhalten Aufschluss zu geben [Ri13].

## 2 Forschungsproblem

In dieser Dissertation [Za22] betrachten wir einen zeitdiskreten stochastischen Prozess  $\mathcal{P}$ , der einen Graphen  $g_t$  im Zeitschritt  $t$ ,  $t \in \mathbb{N}$  erzeugt. Wir nehmen an, dass die erzeugte Sequenz  $(g_t)_{t \in \mathbb{N}} = g_1, g_2, \dots, g_t, \dots$  aus einer stationären, normalerweise unbekanntem, Verteilung  $P_0$  gezogen wird. Wir befassen uns mit dem Problem der Identifizierung

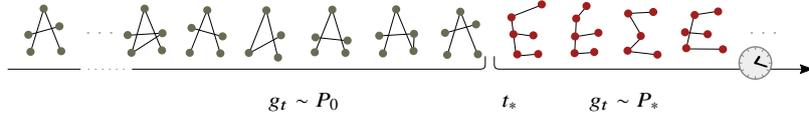


Abb. 2: Ein Beispiel für eine Graphsequenz, die im Zeitschritt  $t_*$  eine Änderung der Stationarität erfährt. Die Graphen  $g_t$  für  $t < t_*$  werden unabhängig und identisch aus einer nominalen Verteilung  $P_0$  gezogen und erzeugen Graphen, die dem Buchstaben "A" ähneln. Graphen  $g_t$  für  $t \geq t_*$ , die nach dem Änderungspunkt erzeugt werden, werden aus einer anderen Verteilung  $P_* \neq P_0$  gezogen und ähneln dem Buchstaben "E".

möglicher Änderungen in der Stationarität, die durch Phänomene verursacht werden, die im zugrunde liegenden stochastischen Prozess auftreten und sich in der Graphsequenz zeigen. Formalisieren lässt sich dieses Problem als Erkennung, ob es einen Zeitschritt  $t_* \in \mathbb{N}$  gibt, bei dem

$$g_t \sim \begin{cases} P_0, & t < t_* \\ P_t, & t \geq t_*, \quad P_{t_*} \neq P_0. \end{cases} \quad (1)$$

Mit anderen Worten, der Prozess  $\mathcal{P}$  befindet sich in einem stationären Zustand, der durch die Verteilung  $P_0$  bestimmt wird, bis zum Zeitschritt  $t_*$ , wenn eine neue Datenverteilung  $P_{t_*} \neq P_0$  auftritt. Nach dem Änderungszeitpunkt  $t_*$  kann das Verhalten des Prozesses  $\mathcal{P}$  beliebig sein. In der Tat erlaubt die Formulierung (1) die Modellierung verschiedener Arten von Veränderungen. Beispielsweise treten abrupte Änderungen auf, wenn für die Verteilungen nach der Änderung  $P_t = P_*$  für  $t \geq t_*$  gilt, also

$$g_t \sim \begin{cases} P_0, & t < t_* \\ P_*, & t \geq t_*, \quad P_* \neq P_0, \end{cases} \quad (2)$$

wie in Abbildung 2 dargestellt. Ebenso können wir Anomalien modellieren, die als sofortige vorübergehende Ereignissen behandelt werden, für welche die Graphen gemäß  $P_0$  verteilt sind, außer für den Zeitschritt  $t_*$ , für den gilt  $g_{t_*} \sim P_*$ :

$$g_t \sim \begin{cases} P_0, & t \neq t_* \\ P_*, & t = t_*, \quad P_* \neq P_0. \end{cases} \quad (3)$$

Es sei darauf hingewiesen, dass kurzzeitige nichtstationäre Störungen, die eine kleine Anzahl von Graphen aus einer anderen Verteilung  $P_*$  erzeugen, ebenfalls als Anomalien behandelt werden können. Jedoch sollten Anomalien von Ausreißern unterschieden werden. Ausreißer sind seltene Beobachtungen, die aus der Nominalverteilung  $P_0$  gezogen sind und mit einer geringen Likelihood assoziiert sind, während anomale Graphen aus einer von  $P_0$  abweichenden Verteilung  $P_*$  gezogen sind [Pi14]. Wenn die Anzahl der Beobachtungen, die mit dem Rest der Daten nicht übereinstimmen, zu gering ist, dann ist die Unterscheidung zwischen Anomalien und Ausreißern schwierig, wenn nicht gar unmöglich, obwohl es sich um konzeptionell unterschiedliche Arten von Beobachtungen handelt und sie als solche betrachtet werden sollten.

Graphen treten heutzutage in unterschiedlichsten Formen auf, die sich aus der Vielzahl der realen Anwendungen ergeben. Wir tragen dieser Variabilität Rechnung, indem wir die Dissertation für das allgemeinere Szenario formulieren, in dem die Topologie von einem Zeitschritt zum anderen variieren kann und in dem sowohl Knoten als auch Kanten mit jeglicher Art von Attribut versehen sein können, einschließlich Vektoren und nicht-numerischen Labels. Darüber hinaus kann eine Eins-zu-eins-Entsprechung zwischen Knoten verschiedener Graphen fehlen oder nicht gegeben sein, was den Vergleich von Graphen zu einem nicht-trivialen und rechnerisch schwierigen Problem macht; ein solcher Mangel an Knoten-Entsprechung wird als Graphen mit nicht identifizierten Knoten bezeichnet.

Soweit wir wissen, gibt es in der Literatur keine Arbeit, die sich mit Problemen der Erkennung von Veränderungen und Anomalien befasst, indem sie generische Familien von Graphen betrachtet, wie wir es in dieser Forschung tun. Der beschriebene Aufbau erfordert die Entwicklung eines dedizierten theoretischen Rahmens und mathematischer Werkzeuge.

### 3 Herausforderungen

Die Verarbeitung von Sequenzen von Graphen mit generischen Attributen und fehlender Korrespondenz der Knoten im Zeitverlauf ist wesentlich komplizierter als der Umgang mit Vektordaten. Wir identifizieren vier Hauptherausforderungen, welche die Identifizierung von Veränderungen der Stationarität in solchen Sequenzen zu einem schwierigen Problem machen.

**C1 Graphenraum:** Die erste Herausforderung besteht darin, die Geometrie des Graphenraums zu verstehen, wenn Graphen mit Attributen versehen sind und nicht identifizierte Knoten haben. Solche Werkzeuge ermöglichen wiederum Methoden des maschinellen Lernens, die geeignete Repräsentationen von Graphen liefern können, wodurch die nachgelagerten Aufgaben in der Praxis leichter zu lösen sind.

**C2 Hypothesentests:** Entwurf von statistischen Tests, die auf Graphsequenzen anwendbar sind. Geeignete Graphenstatistiken werden benötigt, um zwischen verschiedenen Verteilungen zu unterscheiden. Solche Statistiken sollten in der Lage sein, Stichproben von Graphen (Mengen von Graphen) zu verarbeiten, aber auch vielseitig genug sein, um in Streaming-Szenarien, d.h. sequentiell, zu arbeiten.

Tests, die gegen jede Alternativhypothese konsistent sind, erfordern Graphenmaße wie Distanzen und Kernels, die zumindest aussagekräftig genug sind, um zwischen Paaren nicht-isomorpher Graphen zu unterscheiden; wenn die Tests über eine Embedding-Abbildung entworfen werden, muss die Abbildung injektiv sein. Diese Eigenschaften sind schwer zu erfüllen, da sie von der kombinatorischen Natur von Graphen herrühren. Daher haben wir zwei weitere Herausforderungen identifiziert.

**C3 Rechnerische Komplexität:** Entwicklung von rechnerisch machbaren Methoden und robuster Näherungsmethoden. Dies kann den Unterschied ausmachen zwischen einer wirksamen Methode, die zu komplex ist, um in der Praxis angewandt zu werden, und einer Methode, die mit gewissen Einschränkungen eingesetzt werden kann und reale Probleme löst.

**C4 Statistische Aussagekraft:** Entwicklung dateneffizienter Methoden und Verfahren zur Bewältigung von Szenarien, bei denen große Graphen beteiligt sind und eine kleine Anzahl von Graphen gegeben ist. Die Ausnutzung von Eigenschaften der gegebenen Graphen, wie Symmetrien und Zwangsbedingungen, und Resampling-Methoden können die Aussagekraft der Tests erheblich steigern.

Wir haben uns die Herausforderung **C2** als zentrales Ziel der Forschung gesetzt. Die Bewältigung von **C2** wird jedoch durch Fortschritte bei den Herausforderungen **C1**, **C3** und **C4** erleichtert. In der Tat bietet **C1** mathematische Werkzeuge, um Graphen in geeigneten Bereichen zu behandeln und ihre inhärenten Eigenschaften zu nutzen. Auch wenn theoretische Werkzeuge zur Verfügung stehen, sind sie nicht zwangsläufig konstruktiv berechenbar, ebenso mag es sein, dass sie keinen effektiven und effizienten Algorithmus für die Bewertung haben, oder sie auf großen Stichproben basieren; hier kommen **C3** und **C4** ins Spiel.

## 4 Thesisbeiträge

Die in dieser Dissertation [Za22] vorgestellten Arbeiten wurden wissenschaftlichen Konferenzen und Journalen veröffentlicht. Zusammengefasst sind die Beiträge der Dissertation die folgenden.

**Methodik:** Wir formalisieren eine Methodik zur Durchführung von Hypothesentests auf Graphsequenzen, wobei wir die Auswirkungen einer Verlagerung der Analyse von der Domäne der Graphen auf eine zugänglichere Domäne, wie einen Vektorraum oder eine Riemannsche Mannigfaltigkeit, untersuchen [ZAL18; ZAL19]. Die Methodik ermöglicht sowohl die Untersuchung der verfügbaren Methoden zur Erkennung von Veränderungen als auch die Entwicklung neuer Techniken.

**Embeddings auf Graphebene:** Wir geben einen Überblick über wichtige Beziehungen zwischen Graph-Distanzen, -Kernels und -Embeddings und konzentrieren uns bei der Analyse auf Embedding-Methoden, da diese die genannten Vorteile bieten. Wir untersuchen verschiedene Methoden der Graph-Embeddings, die sich in die obige Methodik einfügen [Gr19; ZAL20; ZLA18].

**Tests zur Erkennung von Veränderungen:** Wir zeigen, wie die Methodik durch die Kombination verschiedener Embedding-Methoden mit verschiedenen statistischen Tests in spezifische Tests umgewandelt werden kann [Gr19; ZAL18; ZAL19; ZLA18]. In diesem Zusammenhang schlagen wir Tests zur Erkennung von Änderungen des Mittelwerts der Graphenverteilung sowie von beliebigen Änderungen der Verteilung vor. Wir schlagen statistische Tests vor, die auf Mannigfaltigkeiten operieren, sowie Ensemble-Tests und Tests zur Erkennung mehrerer Änderungen.

Die vorgeschlagenen Methoden wurden anhand verschiedener Arten von Graphsequenzen validiert, darunter Sequenzen synthetischer Graphen [ZLA17; ZLA18], Molekülen [ZAL18; ZAL20] und Netzwerken im Gehirn [Gr19; ZAL19].

## 5 Ausblick

Wir sind der Meinung, dass es wichtig ist, allgemeine und robuste Ansätze zu entwickeln, die den Benutzer von der Aneignung spezieller fachlicher Kenntnisse entlasten und somit eine möglichst breite Anwendbarkeit der Methoden ermöglichen. Es gibt Methoden zur Erkennung von Veränderungen, die gegenüber jeder Veränderung der Verteilung konsistent sind. Solche Methoden sind daher auf praktisch jede Problemstellung und jede Art von Graphen anwendbar, mit nachweislich erwartbarer Leistung. Wir sind uns jedoch auch bewusst, dass sie nicht unbedingt praktikabel sind, da sie möglicherweise eine unrealistische Menge an Daten erfordern oder einfach nicht genügend statistische Aussagekraft für das gegebene Problem haben, was zu langen Erkennungsverzögerungen führt, die den gegebenen Anwendungsanforderungen nicht entsprechen. Umgekehrt können Methoden, die auf spezifische Probleme zugeschnitten sind, in der Praxis per Definition bessere Ergebnisse erzielen als allgemeine Methoden, vorausgesetzt, man ist in der Lage, das verfügbare Wissen effektiv zu nutzen und die geeignete Methode für das jeweilige Problem auszuwählen.

Mit diesem Kommentar betonen wir, dass der methodische Beitrag dieser Doktorarbeit ein Grundgerüst für die Entwicklung neuer maßgeschneiderter Tests bietet und die vorgeschlagenen Methoden insgesamt gute Ausgangspunkte sind, die nach Bedarf weiter angepasst und erweitert werden können. Zukünftige Forschung sollte sich daher auf Techniken konzentrieren, mit denen (i) relevantes Vorwissen ausgewählt, (ii) in die Architektur der maschinellen Lernmodelle integriert und (iii) im Lernprozess wirksam ausgenutzt werden kann. Zu den besten Möglichkeiten, die ich mir von dieser Arbeit verspreche, gehört die Verwendung der vorgeschlagenen Graph Random Neural Features [ZAL20] als vielseitige Vorlage für die Entwicklung neuer Embedding-Methoden; zum Beispiel durch die Identifizierung einer grundlegenden Familie von Graphenfunktionen, die in der Lage sind, Symmetrien und Einschränkungen in der gegebenen spezifischen Problemstellung auszunutzen.

## Literatur

- [ABR13] Alippi, C.; Boracchi, G.; Roveri, M.: Just-in-time classifiers for recurrent concepts. *IEEE transactions on neural networks and learning systems* 24/4, S. 620–634, 2013.
- [ANR13] Alippi, C.; Ntalampiras, S.; Roveri, M.: A cognitive fault diagnosis system for distributed sensor networks. *IEEE transactions on neural networks and learning systems* 24/8, S. 1213–1226, 2013.
- [ANR16] Alippi, C.; Ntalampiras, S.; Roveri, M.: Model-free fault detection and isolation in large-scale cyber-physical systems. *IEEE Transactions on Emerging Topics in Computational Intelligence* 1/1, S. 61–71, 2016.
- [AT05] Adomavicius, G.; Tuzhilin, A.: Toward the next generation of recommender systems: A survey of the state-of-the-art and possible extensions. *IEEE transactions on knowledge and data engineering* 17/6, S. 734–749, 2005.
- [ATK15] Akoglu, L.; Tong, H.; Koutra, D.: Graph based anomaly detection and description: a survey. *Data mining and knowledge discovery* 29/3, S. 626–688, 2015.
- [Ba18] Battaglia, P. W.; Hamrick, J. B.; Bapst, V.; Sanchez-Gonzalez, A.; Zambaldi, V.; Malinowski, M.; Tacchetti, A.; Raposo, D.; Santoro, A.; Faulkner, R. et al.: Relational inductive biases, deep learning, and graph networks. *arXiv preprint arXiv:1806.01261*, 2018.
- [BG07] Bifet, A.; Gavalda, R.: Learning from time-changing data with adaptive windowing. In: *Proceedings of the 2007 SIAM international conference on data mining*. SIAM, S. 443–448, 2007.
- [BN+93] Basseville, M.; Nikiforov, I. V. et al.: *Detection of abrupt changes: theory and application*. prentice Hall Englewood Cliffs, 1993.
- [Bo05] Borgwardt, K. M.; Ong, C. S.; Schönauer, S.; Vishwanathan, S.; Smola, A. J.; Kriegel, H.-P.: Protein function prediction via graph kernels. *Bioinformatics* 21/suppl 1, S. i47–i56, 2005.
- [BS16] Bastos, A. M.; Schoffelen, J.-M.: A tutorial review of functional connectivity analysis methods and their interpretational pitfalls. *Frontiers in systems neuroscience* 9/, S. 175, 2016.
- [CML11] Cho, E.; Myers, S. A.; Leskovec, J.: Friendship and mobility: user movement in location-based social networks. In: *Proceedings of the 17th ACM SIGKDD international conference on Knowledge discovery and data mining*. S. 1082–1090, 2011.
- [Di15] Ditzler, G.; Roveri, M.; Alippi, C.; Polikar, R.: Learning in nonstationary environments: a survey. *IEEE Computational Intelligence Magazine* 10/4, S. 12–25, 2015.

- [EP11] Elwell, R.; Polikar, R.: Incremental learning of concept drift in nonstationary environments. *IEEE Transactions on Neural Networks* 22/10, S. 1517–1531, 2011.
- [Ga14] Gama, J.; Žliobaitė, I.; Bifet, A.; Pechenizkiy, M.; Bouchachia, A.: A survey on concept drift adaptation. *ACM computing surveys (CSUR)* 46/4, S. 1–37, 2014.
- [Gr19] Grattarola, D.; Zambon, D.; Alippi, C.; Livi, L.: Change Detection in Graph Streams by Learning Graph Embeddings on Constant-Curvature Manifolds. *IEEE Transactions on Neural Networks and Learning Systems*, 2019.
- [JM15] Jordan, M. I.; Mitchell, T. M.: Machine learning: Trends, perspectives, and prospects. *Science* 349/6245, S. 255–260, 2015.
- [Li16] Livi, L.; Maiorino, E.; Giuliani, A.; Rizzi, A.; Sadeghian, A.: A generative model for protein contact networks. *Journal of Biomolecular Structure and Dynamics* 34/7, S. 1441–1454, 2016.
- [Li18] Li, Y.; Yu, R.; Shahabi, C.; Liu, Y.: Diffusion Convolutional Recurrent Neural Network: Data-Driven Traffic Forecasting. In: *International Conference on Learning Representations*. 2018, URL: <https://openreview.net/forum?id=SJiHXGWAZ>.
- [LP17] Li, K.; Principe, J. C.: Transfer learning in adaptive filters: The nearest instance centroid-estimation kernel least-mean-square algorithm. *IEEE Transactions on Signal Processing* 65/24, S. 6520–6535, 2017.
- [MH19] Masuda, N.; Holme, P.: Detecting sequences of system states in temporal networks. *Scientific reports* 9/1, S. 795, 2019.
- [Mi80] Mitchell, T. M.: The need for biases in learning generalizations. Department of Computer Science, Laboratory for Computer Science Research . . . , 1980.
- [Pi14] Pimentel, M. A.; Clifton, D. A.; Clifton, L.; Tarassenko, L.: A review of novelty detection. *Signal Processing* 99/, S. 215–249, 2014.
- [Po16] Possemato, F.; Paschero, M.; Livi, L.; Sadeghian, A.; Rizzi, A.: On the impact of topological properties of smart grids in power losses optimization problems. *International Journal of Electrical Power and Energy Systems* 78/, S. 755–764, 2016.
- [Ra15] Ranshous, S.; Shen, S.; Koutra, D.; Harenberg, S.; Faloutsos, C.; Samatova, N. F.: Anomaly detection in dynamic networks: A survey. *Wiley Interdisciplinary Reviews: Computational Statistics* 7/3, S. 223–247, 2015.
- [Ra18] Radovic, A.; Williams, M.; Rousseau, D.; Kagan, M.; Bonacorsi, D.; Himmel, A.; Aurisano, A.; Terao, K.; Wongjirad, T.: Machine learning at the energy and intensity frontiers of particle physics. *Nature* 560/7716, S. 41–48, 2018.
- [Ri13] Richiardi, J.; Achard, S.; Bunke, H.; Van De Ville, D.: Machine learning with brain graphs: predictive modeling approaches for functional imaging in systems neuroscience. *IEEE Signal processing magazine* 30/3, S. 58–70, 2013.

- [SCF00] Sohn, H.; Czarnecki, J. A.; Farrar, C. R.: Structural health monitoring using statistical process control. *Journal of structural engineering* 126/11, S. 1356–1363, 2000.
- [Yo18] You, J.; Liu, B.; Ying, Z.; Pande, V.; Leskovec, J.: Graph convolutional policy network for goal-directed molecular graph generation. In: *Advances in neural information processing systems*. S. 6410–6421, 2018.
- [YXL18] Yan, S.; Xiong, Y.; Lin, D.: Spatial temporal graph convolutional networks for skeleton-based action recognition. In: *Thirty-second AAAI conference on artificial intelligence*. 2018.
- [Za22] Zambon, D.: *Anomaly and Change Detection in Sequences of Graphs*, Diss., Università della Svizzera italiana, 2022.
- [ZAL18] Zambon, D.; Alippi, C.; Livi, L.: Concept Drift and Anomaly Detection in Graph Streams. *IEEE Transactions on Neural Networks and Learning Systems*, S. 1–14, 2018.
- [ZAL19] Zambon, D.; Alippi, C.; Livi, L.: Change-Point Methods on a Sequence of Graphs. *IEEE Transactions on Signal Processing*, 2019.
- [ZAL20] Zambon, D.; Alippi, C.; Livi, L.: Graph Random Neural Features for Distance-Preserving Graph Representations. In (III, H. D.; Singh, A., Hrsg.): *Proceedings of the 37th International Conference on Machine Learning (ICML)*. Bd. 119. *Proceedings of Machine Learning Research*, PMLR, Virtual, S. 10968–10977, 2020, URL: <http://proceedings.mlr.press/v119/zambon20a.html>.
- [ZLA17] Zambon, D.; Livi, L.; Alippi, C.: Detecting Changes in Sequences of Attributed Graphs. In: *IEEE Symposium Series on Computational Intelligence*. 2017.
- [ZLA18] Zambon, D.; Livi, L.; Alippi, C.: Anomaly and Change Detection in Graph Streams through Constant-Curvature Manifold Embeddings. In: *IEEE International Joint Conference on Neural Networks*. 2018.



**Daniele Zambon** ist derzeit Post-Doktorand am Dalle Molle Institut für Künstliche Intelligenz (IDSIA, Schweiz). Seine Forschungsinteressen umfassen das Lernen von Graphenrepräsentationen, Graph Stream Mining und statistische Tests zur Erkennung von Anomalien und Veränderungen. Er promovierte in Informatik an der Università della Svizzera italiana (Schweiz) und erwarb den Master- und Bachelor-Abschluss an der Università degli Studi di Milano (Italien). Er war Gastforscher an der University of Florida (USA) und der University of Exeter (UK). Er war Praktikant bei STMicroelectronics (Italien), wo er seine Masterarbeit schrieb.

Er war Mitglied des Programmkomitees hochrangiger Konferenzen und Fachzeitschriften, darunter IEEE TNNLS, IEEE TSP, IEEE PAMI, NeurIPS, ICLR, ICML, CVPR.