

Analyse und Visualisierung des Energieverbrauchs in Produktionsanlagen

M.Sc. **Alexander Maier**, B.Sc. **Nikolai Schetin**,

Institut Industrial IT, Lemgo;

Dipl.-Ing. **Asmir Vodenčarević**, Prof. Dr. rer. nat. **Hans Kleine Büning**,
Universität Paderborn;

B.Sc. **Florian Pethig**, Prof. Dr. rer. nat. **Oliver Niggemann**,
Fraunhofer IOSB-INA, Lemgo

Kurzfassung

Ein erster Schritt in eine umweltfreundliche und ressourcen-schonende Produktion ist die Erfassung und Analyse des Energieverbrauchs in der Produktionsanlage. Dieser Beitrag schildert die Methodik einer Diagnose des Energieverbrauchs: Zunächst werden die Prozess- und Energiedaten mittels eines speziell entwickelten Datenloggers erfasst. Für die Analyse des Energieverhaltens einer Anlage wird hier eine Methode für das Lernen des normalen Energieverbrauchs und die anschließende Erkennung von Anomalien im Betrieb präsentiert. Die wesentlichen Informationen werden dem Anlagenbediener anschließend in geeigneter Weise z. B. auf mobilen Geräten visualisiert.

1. Einleitung

Die automatische Erkennung des suboptimalen Energieverbrauchs in Produktionsanlagen wird eine große Herausforderung der europäischen Industrie in den nächsten Jahren sein [10], [23]. Die erste und wichtigste Voraussetzung für optimalen Energieverbrauch ist, den normalen Betrieb mit Hilfe frühzeitiger Erkennung von Anomalien sicher zu stellen.

Dafür wurden verschiedene modellfreie Ansätze, wie Hardware-Redundanzen [13] oder Expertensysteme [16], entwickelt. Diese sind jedoch entweder zu teuer, oder sie benötigen umfangreiches Wissen über das System. Die Alternative ist modellbasierte Diagnose [3], [20], die ein Energienormalverbrauchsmodell verwendet. Der wesentliche Vorteil der modellbasierten Diagnose liegt in den präzisen Diagnoseergebnissen. Die Modelle werden heutzutage meistens manuell auf einem zeit- und kostenintensiven Weg erstellt. Hierin liegt ein großes Potential für das automatische Lernen der Modelle. Bild 1 zeigt die vier Schritte, die zur Energieanalyse notwendig sind: *(i)* die Erfassung des Energieverbrauchs, *(ii)* das Lernen des Normalverhaltensmodells, *(iii)* die Anomalieerkennung und *(iv)* die Visualisierung des Energieverbrauchs. Diese vier Schritte werden in den folgenden Kapiteln näher erläutert.

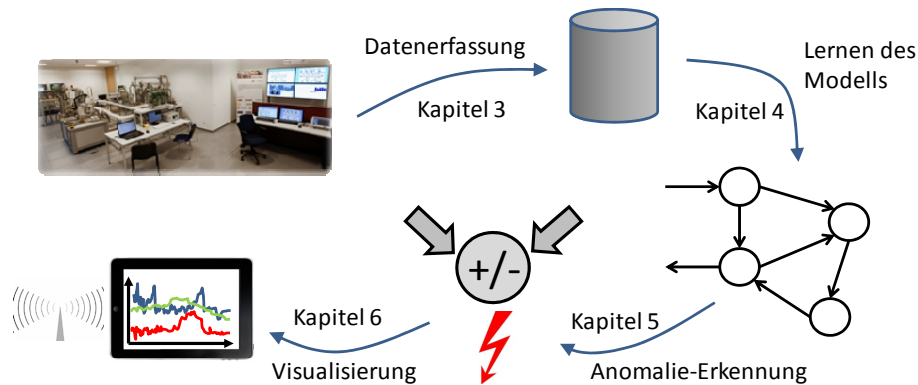


Bild 1: Vier Schritte in der Energieanalyse

2. Stand der Technik

2.1 Datenerfassung

In Maschinen und Anlagen eingesetzte Automatisierungssysteme sind heute oft heterogener Natur [2]. Es werden Komponenten unterschiedlicher Hersteller, sowie unterschiedliche Technologien zur Vernetzung dieser Komponenten eingesetzt. Diese Herangehensweise beim Entwurf einer Anlage führt zu Herausforderungen bezüglich der Prozess- und Energiedatenerfassung.

Prozessdatenerfassung basiert heute häufig auf Technologien wie *OPC (Openness, Productivity, Collaboration)* oder IEC 61131-3 Funktionsbausteinen, z. B. um via *SQL (Structured Query Language)* direkt in eine Datenbank zu schreiben oder Prozessdaten mittels *TCP/IP* an einen *SCADA- (Supervisory, Control and Data Acquisition)* bzw. *History-Server* zu senden. Diese Methoden der Datenerfassung sind hierbei für viele Applikationen, insbesondere in der Prozess- und Verfahrenstechnik, ausreichend. Jedoch wird ein vermehrtes Interesse an intelligenten Diagnose-Funktionalitäten auch für schnelle Prozesse, z. B. Motion-Applikationen in der Fertigungsautomatisierung, beobachtet. Hier erreichen Industrial-Ethernet-Systeme wie EtherCAT oder PROFINET Zykluszeiten < 1 ms [14]. Diesen zeitlichen Anforderungen muss ebenfalls die Datenerfassung gerecht werden. Die beschriebenen State-Of-The-Art Lösungen sind dabei nicht in der Lage, eine synchronisierte Erfassung in verteilten Automatisierungssystemen mit der geforderten Genauigkeit zu leisten [18]. Lassen zwar z. B. PROFINET oder auch EtherCAT selbst die Zeitsynchronisation mit einer Genauigkeit < 1 ms zu [5] [11], so ist es heute doch de facto nicht möglich, Komponenten verschiedener Systeme miteinander zu synchronisieren. Bild 2 verdeutlicht dieses Problem.

Speziell die Energiedatenerfassung erfolgt heute mit Smart-Metern und Multifunktionsmessgeräten, die über keine eigenen Synchronisationsmechanismen in dem geforderten Genauigkeitsbereich verfügen. Der Ethernet-basierte Zeitsynchronisationsstandard IEEE 1588 [12]

könnte allerdings die Basis für eine geeignete Lösung darstellen. Viele Smart-Meter besitzen bereits Ethernet-Interfaces, unterstützen jedoch zumeist lediglich Protokolle mit schwachen Echtzeit-Charakteristika (z. B. keine deterministische Übertragung) zum Abruf ihrer Messwerte (z. B. MODBUS/TCP). Trotz erster Produktvarianten mit EtherCAT- und PROFINET-Unterstützung ist noch großes Potential für Smart-Meter in der industriellen Automation mit Echtzeitprotokollen und Synchronisationsmechanismen zu erkennen.




Bild 2: Unsynchronisierte Energiedatenerfassung in heterogenen Automatisierungssystemen

Die Instrumentalisierung der vorhandenen Automatisierungstechnik für den Zweck der Energiedatenerfassung spielt ebenfalls eine bedeutende Rolle. Hier existieren spezielle Klemmen für die Leistungserfassung, die eine Vorverarbeitung der Messwerte direkt in der Klemme selbst durchführen, sowie Technologien wie z. B. Oversampling, die die Verwendung von herkömmlichen analogen Eingangsklemmen ermöglichen. Hierdurch wird die Installation zusätzlicher Messtechnik obsolet.

Ambitionen um existierende Automatisierungskomponenten für das Energiemanagement zu nutzen, sind außerdem in Spezifikationen spezieller Energieprofile für Industrial- Ethernet Protokolle, wie z. B. PROFIenergy [19] und SERCOEnergy [21] zu erkennen.

2.2 Überwachung und Optimierung des Energieverbrauchs

Die Überwachung und Optimierung des Energieverbrauchs von Produktionsprozessen ist aktuell ein sehr aktives Forschungsfeld. Derzeit liegt der Fokus aber häufig auf der Steigerung der Energieeffizienz einzelner Bauteile oder Baugruppen; z. B. die bessere Auslegung von Antrieben. Zur Reduktion des Energieverbrauchs in Produktionsanlagen werden derzeit hauptsächlich passive Maßnahmen durchgeführt. Dazu gehören zum Beispiel Analysen und Maßnahmen, die in der Planungsphase durchgeführt werden. So wird zum Beispiel im Projekt „e-SimPro“ [7] der Energieverbrauch einer Anlage im Vorfeld simuliert um Schwachstellen bzw. Verbesserungspotenzial zu ermitteln.

Weitere Arbeiten konzentrieren sich auf die Effizienzsteigerung während der Planungs- und Konstruktionszeit im Vorfeld des Betriebs. Außerdem liegt der Fokus häufig auf der sparsamen Verwendung von Ressourcen/ Rohstoffen (z. B. [6], [8] und [17]).

Ein Beispiel für eine aktive Überwachung des Energieverbrauchs wird in [4] gezeigt. Der Fokus liegt dabei auf dem Produktionsprozess. Am Beispiel eines Fräsprozesses wird gezeigt, wie der Energieverbrauch modelliert werden kann: Es werden Diagramme (Profile) erstellt, in denen einzelne Phasen des Fräsprozesses erkennbar sind. Diese Diagramme können für die Optimierung genutzt werden. Außerdem ist damit eine Vorhersage des Energieverbrauchs möglich, da anhand des Diagramms ständig bekannt ist, in welcher Phase sich die Anlage derzeit befindet. Somit könnte möglicherweise bereits im Vorfeld auf bestimmte Ereignisse „reagiert“ werden.

2.3 Lernen des Normalverhaltens

Ein Beispiel für das Erlernen des Normalverhaltens ist die Modellgenerierung mittels selbstorganisierender Karten (self-organizing maps, SOMs, z. B. in [9]). Anwendung findet dieses Konzept in der Prozessdiagnose feldbusorientierter Automatisierungsanlagen in der Verfahrenstechnik. Es werden Softwareagenten eingesetzt, die kontinuierlich die auf den Feldbus übertragenen Nachrichten analysieren und charakteristische Merkmale extrahieren. Anschließend werden die Merkmale von einem Diagnosemanager zusammengefasst.

Isermann [13] beschäftigt sich u.a. mit der modellbasierten Zustandsbeobachtung eines Systems (zumeist in der Automobilindustrie, z. B. Motoren). Für diesen Zweck wird ein regelungstechnisches Modell (i. A. mittels gewöhnlicher Differentialgleichungen) des Systems manuell erstellt. Die Modellparameter werden in einem nachfolgenden Schritt automatisch ermittelt („model identification“). Im laufenden Betrieb der Anlage wird das Verhalten zusätzlich parallel zum regulären Betrieb mithilfe des Modells simuliert. Bei Abweichungen im Verhalten wird die Fehlerursache ermittelt, dieser letzte Schritt geschieht zumeist mit einfachen Klassifikationsmethoden wie z. B. „k-nearest-neighbour“.

Hybride Endliche Automaten sind gut geeignet, um sequentielle Abläufe zu modellieren. Es existieren unterschiedliche Ansätze für das Lernen des Normalverhaltens mittels endlicher Automaten. Während das Lernen von probabilistischen Automaten mehrfach behandelt wird (z. B. ALERGIA in [1] oder MDI in [22]), zählt das Lernen von temporalen Automaten erst in jüngerer Zeit zum Forschungsinteresse (z. B. RTI+ in [24] oder BUTLA in [15]). Für das Lernen von Hybriden Automaten existiert bislang lediglich ein Algorithmus (HyBUTLA [25]).

3. Erfassung des Energieverbrauchs

Zur Energiedatenerfassung werden hier Multifunktionsmessgeräte (Smart Meter) verwendet, welche unter anderem aktuelle Werte für Wirk- und Blindleistung, sowie Amplituden der Oberschwingungsströme zur Verfügung stellen. Die aktuellen Messwerte werden hierbei

über das Ethernet-basierte Protokoll Modbus/TCP Speicher-programmierbaren Steuerungen (SPS) zur Verfügung gestellt. Um dabei auch in verteilten Anlagen mit einheitlicher Zeitbasis Energiedaten erfassen zu können, wird ein universeller Datalogger eingesetzt. Dieser bietet folgende Vorteile für die Datenerfassung: (i) Zeitsynchronisation mit einer Genauigkeit < 1ms, (ii) Keine Beeinflussung der Anlagenkonfiguration, (iii) Unterstützung mehrerer industrieller Ethernet-Systeme, (iv) Exakte Zeitstempelung auch in sehr großen, verteilten Systemen.

Der Datalogger speichert transparent den Netzwerk-Traffic des Ethernet-Netzwerkes, indem Frames direkt durchgeleitet und lediglich zeitgleich zur Analyse kopiert werden. Die Zeitstempelung, realisiert als Hardware-Modul, erfolgt hierbei ebenfalls direkt bei Eintreffen eines Frames. Um hierbei den Zeitstempel möglichst genau generieren zu können, wird der Datalogger möglichst nah an der zu messenden Sensorik platziert.

Mehrere Datalogger sind außerdem in der Lage, sich mittels des *Precision Time Protocol* (PTP) nach IEEE-1588 zu synchronisieren [12]. Das Prinzip ist in Bild 3 dargestellt.

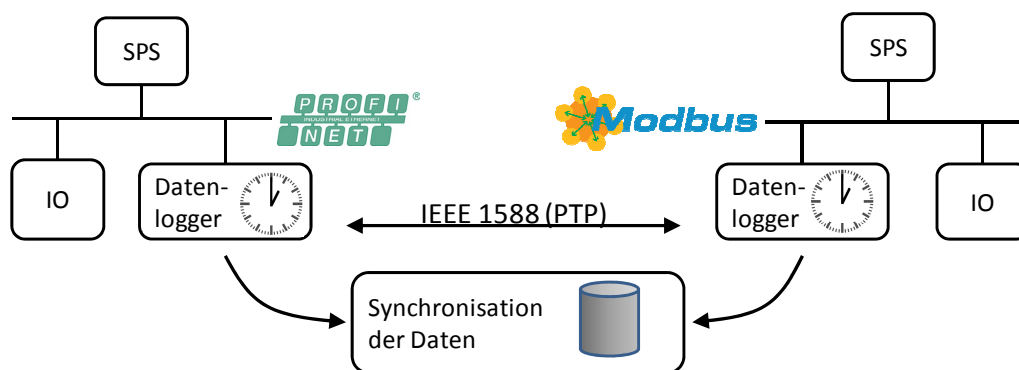


Bild 3: Synchronisation mehrerer Datalogger

Um Variablen bzw. Energieparameter aus den Ethernet-Frames extrahieren zu können, implementiert der Datalogger zum einen die entsprechende Protokolllogik und zum anderen können Informationen aus Engineering-Tools, z. B. nach IEC 61131-3, importiert werden. So ist der Datalogger in der Lage, unter Verwendung der in den Engineering-Tools vergebenen Variablennamen die entsprechenden Werte, ergänzt um einen sehr exakten Zeitstempel, zur Verfügung zu stellen.

Für den Datenzugriff wird des Weiteren die OPC Unified Architecture (OPC UA) verwendet. Diese ermöglicht durch die Verwendung von Web-Services einen globalen und sicheren Zugriff auf die erfassten Energiedaten über das Internet. Außerdem ist die OPC UA plattformunabhängig, sodass der Datenzugriff auch von mobilen Endgeräten wie Tablets und Smartphones möglich ist. Zusätzlich beinhaltet die OPC UA ein explizites Informationsmodell, das es ermöglicht, komplexe Datentypen abzubilden. Somit können nicht nur Variablen mit einem

Namen und einem Wert, sondern auch eine zugehörige Semantik abgebildet und übertragen werden. Für die Energiedatenerfassung wird hierbei z. B. der genaue Ort der Messung, die verwendete Sensorik, sowie die aktuelle Anlagenkonfiguration festgehalten. Sogar momentane Produktionsaufträge, z. B. aus *Manufacturing Execution Systems (MES)*, können auf einfache Art und Weise mit gemessenen Energiewerten korreliert werden. Erst diese Semantik ermöglicht automatische Analysen durch ein Energiemanagement-System ohne eine zu starke Abhängigkeit vom Menschen als Entscheidungsträger.

4. Lernen des Energieverbrauchsmodells

Um Aussagen bezüglich der Korrektheit eines Prozessablaufs treffen zu können muss der normale Energieverbrauch bekannt sein. Dieser lässt sich mithilfe eines Modells festhalten. Folgende Anforderungen an den Modellformalismus müssen erfüllt werden.

Modellierung der Zeit: Technische Systeme/ Produktionsanlagen sind grundsätzlich abhängig von Zeit. Aus diesem Grund muss der verwendete Algorithmus die Zeit explizit modellieren können.

Abhängigkeitsmodellierung: Der Energieverbrauch einer Anlage ist abhängig von dem momentanen Anlagenzustand. Es ist eine Reaktion auf die Eingangsdaten (Sensoren und evtl. auch Aktoren). Diese Abhängigkeit sollte im Modellformalismus berücksichtigt werden.

Hybride Modellierung: In Produktionsanlagen kommen sowohl diskrete als auch kontinuierliche Signale vor, Energiedaten liegen ausschließlich als kontinuierliche Werte vor. Dementsprechend sollte der verwendete Formalismus hybride Daten modellieren können.

Lernbarkeit: Eine wesentliche Anforderung an den Formalismus ist die Lernbarkeit des Modells. Aus Beobachtungen an der Automatisierungstechnik sollte das Modell weitestgehend automatisch ermittelt werden.

Mode-Modellierung: Das System kann zu einem Zeitpunkt das Verhalten grundsätzlich ändern. Beispielweise ändert sich bedingt durch eine Änderung der Ventilstellung nicht nur der Prozess, sondern auch der Energieverbrauch. Der gewählte Modellierungsformalismus sollte dieses ebenfalls modellieren können.

Hybride Automaten sind hervorragend für die Modellierung zeitlicher Abfolgen geeignet. Bild 4 zeigt ein Beispiel eines Hybriden Automaten: Der Zustandsübergang zwischen den Zuständen „Förderband läuft“ und „Förderband steht“ wird getriggert vom Event „stopp“. Als Zeitbedingung ist „ $t < 50$ “ angegeben. Weiterhin wird eine Übergangswahrscheinlichkeit von $p=0,8$ angegeben. In den Zuständen sind kontinuierliche Wertänderungen analoger Kenngrößen (z. B. die elektrische Leistung) erlaubt.

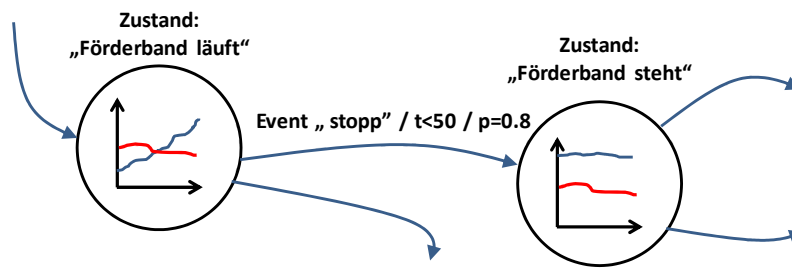


Bild 4: Hybrider Automat

Basierend auf den Messungen (siehe Kapitel 3) wird ein Energieverbrauchsmodell gelernt. Der Vorgang ist in Abbildung 5 dargestellt:

1. **Erstellung des Prefixtrees:** Zunächst wird ein Baum mit den aufgezeichneten Events erstellt (Prefixtree). Beginnend mit einem Initialzustand wird mit jedem Event ein neuer Zustand erstellt. Identische Signalfolgen werden gemeinsam genutzt. Ein Event beschreibt einen grundsätzlichen Systemwechsel. Dies wird im Allgemeinen durch ein diskretes Signal (z. B. Öffnen eines Ventils) ausgelöst. Innerhalb der generierten Zustände werden kontinuierliche Verläufe (z. B. Energiemessungen) approximiert.
2. **State Merging:** Sämtliche Zustände im Prefixtree werden nun paarweise auf Kompatibilität überprüft. Sind die Zustände kompatibel können sie zusammengefasst werden. Zur Prüfung der Kompatibilität werden sowohl die Events der ein- und ausgehenden Zustandsübergänge als auch die kontinuierlichen Funktionen der Zustände verwendet.




Bild 5: Lernen des Energiemodells in Form von Hybriden Automaten

Der gelernte Hybride Automat enthält sowohl Informationen des beobachteten Prozesses (Zustandsabfolge), als auch die zugehörigen Energieinformationen in Form von Kurven über der Zeit innerhalb der Zustände.

5. Diagnose des Energieverbrauchs

Das gelernte Modell simuliert einen optimalen Energieverbrauch der Anlage. Das reale Anlagenverhalten wird, wie in Bild 6 gezeigt, mit der Prognose des Modells verglichen. Bei einer eventuell auftretenden Abweichung wird ein Fehler signalisiert. Der Vergleich wird mit einem

Anomalieerkennungs-Algorithmus, wie beispielsweise ANODA [25], ausgeführt. Dieser Algorithmus erkennt Anomalien sowohl in kontinuierlichen als auch diskreten Teilen des Systems und zielt auf die folgenden drei Anomalie-Typen ab:

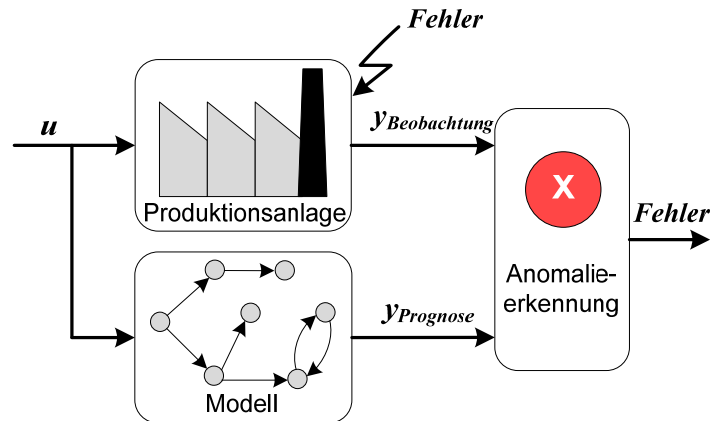


Bild 6: Modellbasierte Anomalieerkennung

1. **Anomaler Energieverbrauch:** Unter- und Überschreiten der elektrischen Leistung sind anhand der Prognose des Hybriden Automaten zu erkennen.
2. **Kontrollabfolge-Anomalien:** Fehler im Regelsystem führen oft zu unbekanntem Betriebsbedingungen. Diese zu erkennen ist eine wichtige Voraussetzung für Energieeffizienz.
3. **Zeit-Anomalien:** Suboptimaler Betrieb kann auch entstehen, wenn die Kontrollabfolge korrekt ist. Das geschieht, wenn die Zeit der Events gestört ist. ANODA kann solches Verhalten auch erkennen.

Der neue Ansatz zum Modelllernen und Anomalieerkennung wurde in einer realen Situation evaluiert. Die Experimente wurden in einer experimentellen Produktionsanlage, der Lemgoer Modellfabrik, ausgeführt. Das gelernte Modell umfasst 19 Zustände und ist etwa 63% kleiner als der Prefixtree. Beobachtetes Signal war die elektrische Leistung, die in einem Bereich von 0-1150 W gemessen wurde. Bei dem HyBUTLA Algorithmus wurden die Messungen aus 12 Produktionszyklen zum Lernen verwendet, die aus sechs kontinuierlichen und sechs diskreten Signalen bestehen.

Ungefähr 20% der Messungen des Produktionszyklus waren anomal. Die Erkennungsrate wurde für folgende Anomalien betrachtet: (A1) Unterschreiten der elektrischen Leistung um 10%, (A2) Überschreiten der elektrischen Leistung um 10%, (A3) Kontrollabfolge-Anomalie, und (A4) Zeit-Anomalie. Das Experiment wurde 100 mal wiederholt. Die durchschnittliche Sensitivität (Richtig-Positiv-Rate), Spezifität (Richtig-Negativ-Rate) und Gesamtgenauigkeit der Erkennung sind in der Tabelle 1 zusammengefasst.

Tabelle 1: Die Genauigkeit der Anomalieerkennung [25]

Leistung	Anomalie-Typ			
	A1	A2	A3	A4
Sensitivität (%)	97.12	98.29	100	100
Spezifität (%)	92.98	93.95	100	100
Gesamtgenauigkeit (%)	93.82	94.83	100	100

Alle Anomalien in den diskreten Signalen wurden erkannt, da ein deterministischer Test benutzt wurde. Die Anomalieerkennung in den kontinuierlichen Signalen war eine größere Herausforderung, da diese von der Prognose der Regressionsfunktionen abhängt. Auch hier zeigt der präsentierte Ansatz eine gute Leistung.

6. Visualisierung des Energieverbrauchs

Für die Visualisierung sammelt ein Datenlogger die Energieverbrauchsdaten einer Anlage und stellt diese in einer Datenbank zur Verfügung. Diese Daten werden anschließend für unterschiedliche Zwecke – z. B. Monitoring oder Anomalieerkennung – visualisiert. In dem präsentierte Ansatz werden die momentanen Energieverbrauchsdaten der Anlage in einem Live-Gantt-Diagramm visualisiert. Hierfür werden der momentane Verbrauch und die laufende Zeit als Diagrammachsen benutzt. Anhand dieser Diagramme kann auch auf das Anlagenverhalten zurückgeschlossen werden. Dies ist in Bild 7 dargestellt.




Bild 7: Visualisierung des Energieverbrauches

Die über einen Zeitraum gespeicherten Energieverbrauchsdaten können für die Visualisierung eines Trends genutzt werden. Mithilfe dieser Trendbilder kann z. B. ein durch Ver-

schleiß ausgelöster schleichender Energieverbrauchsanstieg festgestellt werden. An der Visualisierung des Energieverbrauchstrends wird zurzeit geforscht.

Der Energieverbrauch kann ebenfalls auf mobilen Geräten visualisiert werden. Dafür wurden schon Anwendungen z. B. für Android- oder iOS Geräte implementiert. Die Visualisierung des Energieverbrauchs auf einem iOS-Gerät ist in der Bild 8 dargestellt.



Bild 8: Visualisierung der Energiedaten auf einem iPad

Da die Visualisierung der Energiedaten auf unterschiedlichen Geräten (z. B. iPad oder Android-Smartphone) genutzt wird, sollte die Verarbeitung der Energiedaten plattformunabhängig sein. Dafür wird das OPC Unified Architecture (UA) eingesetzt, die sowie Web-Service-basierte Kommunikation als auch plattformunabhängige Verarbeitung der Energiedaten ermöglicht.

7. Zusammenfassung und Ausblick

In diesem Beitrag wurde eine Methode zur Analyse des Energieverbrauchs in Produktionsanlagen vorgestellt. Für die Erfassung der Prozessdaten wurde ein Datenlogger vorgestellt, der den Datenverkehr passiv mitschneidet und analysiert. Zusätzlich werden die Energieverbrauchsdaten erfasst. Sowohl die Prozess-, als auch die Energiedaten werden genutzt um ein Energieverbrauchsmodell zu lernen. Dazu wird der Anlagenbetrieb über einen gewissen Zeitraum beobachtet. Die Beobachtungen werden gesammelt und mithilfe eines Algorithmus zu einem Modell abstrahiert. Das gelernte Modell wird anschließend zur Erkennung von anomalem Verhalten verwendet, indem das Anlagenverhalten mit der Prognose des Modells verglichen wird. Abschließend werden die Daten in geeigneter Weise auf mobilen Geräten für den Anwender visualisiert. Die Wirksamkeit der Methode wurde in einem Experiment mit guten Ergebnissen belegt.

In weiteren Arbeiten sollen die erkannten Anomalien ausgewertet werden, um die Produktionsanlage effizienter betreiben zu können.

Literatur

- [1] Carrasco, R. C.; Oncina, J.: Learning deterministic regular grammars from stochastic samples in polynomial time. In RAIRO (Theoretical Informatics and Applications), page 33(1):120, 1999
- [2] Charatsis, K.J.; Kalogeras, A.P.; Georgoudakis, M.; Papadopoulos, G.: Integration of Semantic Web Services and Ontologies into the Industrial and Building Automation Layer, EUROCON. The International Conference on "Computer as a Tool", pp.478-483, 9-12 Sept. 2007
- [3] De Kleer, J.; Williams, B. C.: Diagnosing Multiple Faults. Artificial Intelligence, vol. 32, no. 1, pp. 97–130, 1987
- [4] Dietmair, A.; Verl, A.: Energy consumption modeling and optimization for production machines. In Sustainable Energy Technologies 2008. ICSET 2008. IEEE International Conference on, pages 574 –579, November 2008
- [5] DIN EN 61158-5-10:2008-09, Industrielle Kommunikationsnetze - Feldbusse - Teil 5-10: Dienstfestlegungen des Application Layer (Anwendungsschicht) - Typ 10-Elemente (IEC 61158-5-10:2007)
- [6] EnHiPro. Energie- und hilfsstoffoptimierte Produktion. www.enhipro.de. Laufzeit 06/2009-05/2012
- [7] eSimPro. Effiziente Produktionsmaschinen durch Simulation in der Entwicklung. www.esimpro.de
- [8] EWOTeK. Effizienzsteigerung von Werkzeugmaschinen durch Optimierung der Technologien zum Komponentenbetrieb. www.ewotek.de. Projektdauer: 01.07.2009 - 30.06.2012
- [9] Frey, C. W.: Diagnosis and monitoring of complex industrial processes based on self-organizing maps and watershed transformations. In IEEE International Conference on Computational Intelligence for Measurement Systems and Applications, 2008
- [10] Group, H.-L. MANUFUTURE - Strategic Research Agenda. Technical report, European Commission, 2006
- [11] IEC 61158-3/4/5/6-12 (Ed.1.0), Industrial communication networks – Fieldbus specifications – Part 3-12: Data-link layer service definition – Part 4-12: Data-link layer protocol specification – Part 5-12: Application layer service definition – Part 6-12: Application layer protocol specification – Type 12 elements (EtherCAT)

- [12] IEC/IEEE, Precision Clock Synchronization Protocol for Networked Measurement and Control Systems, IEC 61588 First edition 2004-09; IEEE 1588, 2004
- [13] Isermann, R.: Fault-Diagnosis Systems: An Introduction from Fault Detection to Fault Tolerance. 1st ed. Springer, 2006
- [14] Jasperneite, J.; Schumacher, M.; Weber, K.: Limits of increasing the performance of Industrial Ethernet protocols. IEEE Conference on Emerging Technologies and Factory Automation 2007, ETFA, pp.17-24, 25-28 Sept. 2007
- [15] Maier, A.; Vodenčarević, A.; Niggemann, O.; Just, R.; Jäger, M.: Anomaly Detection in Production Plants using Timed Automata. In: 8th International Conference on Informatics in Control, Automation and Robotics (ICINCO), Noordwijkerhout, Niederlande, Jul 2011
- [16] Mohammadi, R.: Fault diagnosis of hybrid systems with applications to gas turbine engines. Ph.D. dissertation, Concordia University, Montreal, Canada, 2009
- [17] NCPlus. Prozess- und wertschöpfungs-orientiert gesteuerte Werkzeugmaschine. www.ncplus.de. Projektdauer: 01.07.2009 - 30.06.2012
- [18] Pethig, F.; Niggemann, O.: A Multi-Platform Process Monitoring Architecture for Distributed Industrial Networks. Embedded world Conference 2012, Nürnberg, Feb 2012
- [19] PI International, Common Application Profile PROFIenergy, Technical Specification for PROFINET, Version 1.0, 2010
- [20] Reiter, R.: A Theory of Diagnosis from First Principles. Artificial Intelligence, vol. 32, no. 1, pp. 57–95, 1987
- [21] sercos International e.V., Whitepaper sercos Energy, 2012
- [22] Thollard, F.; Dupont, P.; de la Higuera, C.: Probabilistic dfa inference using kullback-leibler divergence and minimality. In Proc. 17th International Conf. on Machine Learning, pages 975–982, Morgan Kaufmann, 2000
- [23] VDI/VDE. Automation 2020 - Bedeutung und Entwicklung der Automation bis zum Jahr 2020, 2009
- [24] Verwer, S.: Efficient Identification of Timed Automata: Theory and Practice. PhD thesis, Delft University of Technology, 2010
- [25] Vodenčarević, A.; Kleine Büning, H.; Niggemann, O.; Maier, A.: Using behavior models for anomaly detection in hybrid systems. In Proceedings of the 23rd Intl. Symposium on Information, Communication and Automation Technologies (ICAT 2011), 2011