

**Universität
Fakultät**

VORLAGE FÜR

**Analyse der Schlafqualität anhand täglicher Gewohnheiten
mit Python und maschinellem Lernen**

Name Nachname

Fachbereich **XXX**

01.07.26

Unsere Lösungsskizzen dienen ausschließlich als wissenschaftliche Vorlage für Ihre Arbeit. Ihre weitere Verwendung ist lediglich zur eigenen gedanklichen Auseinandersetzung vorgesehen und nicht dafür gedacht, als eigene Leistung übernommen zu werden. Die Verantwortung für die korrekte Nutzung liegt beim Kunden.

Abstract

Diese Arbeit untersucht den Zusammenhang zwischen täglichen Gewohnheiten und Schlafqualität mithilfe einer Python gestützten Datenanalyse und ausgewählter Verfahren des maschinellen Lernens. Im Mittelpunkt stehen alltagsnahe Merkmale wie Schlafdauer, Bildschirmzeit, Koffeinkonsum, körperliche Aktivität, Stressniveau sowie Arbeits- beziehungsweise Lernzeit. Ziel ist es, erkennbare Muster innerhalb der untersuchten Daten sichtbar zu machen und zu prüfen, in welchem Umfang diese Merkmale zur Einschätzung der Schlafqualität beitragen können. Methodisch verbindet die Arbeit deskriptive Auswertungen, grafische Darstellungen, Korrelationsanalysen und regressionsbasierte Modellierung. Dabei werden insbesondere Lineare Regression (LR) und Random-Forest-Regression (RFR) berücksichtigt. Die Ergebnisse zeigen, dass Schlafqualität nicht durch einen einzelnen Faktor erklärt werden kann, sondern aus dem Zusammenspiel mehrerer alltäglicher Bedingungen entsteht. Besonders Stressniveau, Bildschirmzeit und Schlafdauer erweisen sich als relevante Merkmale für die datenbasierte Einschätzung. Zugleich wird deutlich, dass maschinelle Lernmodelle zwar hilfreiche Muster sichtbar machen, jedoch keine klinische Bewertung ersetzen. Die Arbeit zeigt damit, wie datenanalytische Methoden genutzt werden können, um verhaltensbezogene Zusammenhänge im Bereich Schlafqualität strukturiert und nachvollziehbar zu untersuchen.

Schlüsselwörter: Schlafqualität, tägliche Gewohnheiten, Python, Datenanalyse

Inhaltsverzeichnis

ABSTRACT	II
INHALTSVERZEICHNIS	III
TABELLENVERZEICHNIS	IV
ABBILDUNGSVERZEICHNIS	V
ABKÜRZUNGSVERZEICHNIS.....	VI
1 EINLEITUNG	7
2 THEORETISCHE GRUNDLAGEN.....	8
2.1 SCHLAFQUALITÄT ALS GESUNDHEITSBEZOGENES VERHALTENSMERKMAL.....	8
2.2 EINFLUSS TÄGLICHER GEWOHNHEITEN AUF DIE SCHLAFQUALITÄT	10
2.3 DATENANALYSE UND MASCHINELLES LERNEN IN VERHALTENSBEZOGENEN UNTERSUCHUNGEN.....	11
3 METHODIK	12
3.1 METHODISCHER ANSATZ	12
3.2 DATENBASIS UND BETRACHTETE MERKMALE	14
3.3 ANALYSEPROZESS MIT PYTHON	16
3.4 MODELLBILDUNG UND EVALUATIONSMETRIKEN	17
4 ERGEBNISSE UND DISKUSSION.....	19
4.1 DESKRIPTIVE ANALYSE UND ZUSAMMENHÄNGE DER UNTERSUCHTEN DATEN	19
4.2 MODELLIERUNGSERGEBNISSE UND KRITISCHE EINORDNUNG	21
5 ZUSAMMENFASSUNG UND AUSBLICK.....	25
LITERATURVERZEICHNIS	27

Tabellenverzeichnis

Tabelle 3.1 Deskriptive Kennwerte der betrachteten Merkmale.....	14
Tabelle 3.2 Betrachtete Merkmale der Datenbasis.....	15

Abbildungsverzeichnis

Abbildung 4.1 Korrelationsmatrix der Alltagsgewohnheiten und Schlafqualität	20
Abbildung 4.2 Merkmalsbedeutung im Random-Forest-Modell	22
Abbildung 4.3 Vergleich zwischen beobachteten und vorhergesagten Schlafqualitätswerten.....	24

Abkürzungsverzeichnis

LR: Lineare Regression

MAE: Mean Absolute Error

RFM: Random-Forest-Modell

RFR: Random-Forest-Regression

RFRM: Random-Forest-Regressionsmodell

R^2 : R-squared

RMSE: Root Mean Squared Error

1 Einleitung

Schlafqualität ist ein wichtiger Bestandteil des alltäglichen Wohlbefindens und beeinflusst Leistungsfähigkeit, Konzentration und gesundheitliche Stabilität. Gleichzeitig verändern digitale Medien, lange Bildschirmzeiten, unregelmäßige Tagesabläufe, Stress und geringe körperliche Aktivität das Schlafverhalten vieler Menschen. Diese Entwicklungen machen Schlafqualität zu einem relevanten Untersuchungsfeld für verhaltensbezogene Datenanalysen (Lund et al., 2010). Besonders interessant ist dabei, wie einzelne Gewohnheiten miteinander zusammenhängen und welche Faktoren Hinweise auf eine bessere oder schlechtere Schlafqualität geben. Diese Arbeit greift diesen Zusammenhang auf und zeigt, wie Python gestützte Datenanalyse und maschinelles Lernen genutzt werden können, um alltagsnahe Muster in strukturierten Daten sichtbar zu machen (Zimmerman et al., 2024).

Obwohl Schlafqualität im Alltag häufig als persönliches Empfinden betrachtet wird, entsteht sie aus mehreren miteinander verbundenen Verhaltensmustern. Bildschirmzeit, Koffeinkonsum, Bewegungsverhalten, Stressbelastung und Schlafdauer wirken nicht isoliert. Sie können sich gegenseitig verstärken oder abschwächen. Dadurch ist es schwierig, einzelne Einflussfaktoren ohne systematische Analyse zu bewerten. Hinzu kommt, dass subjektive Einschätzungen oft ungenau sind. Personen nehmen etwa lange Bildschirmzeiten oder hohe Stresswerte nicht immer als direkte Belastung für den Schlaf wahr (Irish et al., 2015). Vor diesem Hintergrund besteht das Problem darin, alltagsbezogene Einflussgrößen auf Schlafqualität datenbasiert zu untersuchen. Die Arbeit setzt an diesem Punkt an und analysiert, welche Muster in den untersuchten Daten erkennbar sind. Zudem wird betrachtet, wie diese Muster mithilfe von Python und maschinellem Lernen interpretiert werden können (Sejbuk et al., 2022).

Ziel der Arbeit ist es, den Zusammenhang zwischen täglichen Gewohnheiten und Schlafqualität datenbasiert zu untersuchen. Im Mittelpunkt stehen dabei Verhaltensmerkmale wie Bildschirmzeit, Koffeinkonsum, körperliche Aktivität, Stressniveau, Arbeits- beziehungsweise Lernzeit und Schlafdauer. Diese Faktoren werden nicht nur einzeln betrachtet, sondern in ihrem gemeinsamen Einfluss auf die Schlafqualität analysiert. Die Arbeit verfolgt zudem das Ziel, einen nachvollziehbaren Python gestützten Analyseprozess dar-

zustellen. Dazu werden deskriptive Auswertungen, grafische Darstellungen, Korrelationsanalysen und Modelle des maschinellen Lernens eingesetzt. Auf diese Weise soll gezeigt werden, wie verhaltensbezogene Daten strukturiert ausgewertet werden können. Gleichzeitig wird geprüft, in welchem Umfang maschinelle Lernmodelle zur Einschätzung der Schlafqualität beitragen können.

Der weitere Aufbau der Arbeit ist wie folgt gegliedert. Kapitel 2 stellt die theoretischen Grundlagen dar. Dabei wird Schlafqualität zunächst als gesundheitsbezogenes Verhaltensmerkmal eingeordnet. Anschließend werden zentrale tägliche Gewohnheiten betrachtet, die mit Schlafqualität in Verbindung stehen können. Ergänzend wird erläutert, welche Bedeutung Datenanalyse und maschinelles Lernen für verhaltensbezogene Untersuchungen besitzen. Kapitel 3 beschreibt das methodische Vorgehen der Arbeit. Es umfasst das Forschungsdesign, die Untersuchungsvariablen, die Datenbasis, den Analyseprozess mit Python sowie die verwendeten Evaluationsmetriken. Kapitel 4 präsentiert und diskutiert die Ergebnisse. Dabei werden deskriptive Befunde, Zusammenhänge zwischen Alltagsgewohnheiten und Schlafqualität sowie die Ergebnisse der maschinellen Lernmodelle ausgewertet. Kapitel 5 fasst die zentralen Erkenntnisse zusammen und gibt einen Ausblick auf mögliche weitere Untersuchungen.

2 Theoretische Grundlagen

Dieser Abschnitt stellt die theoretischen Grundlagen dar, indem Schlafqualität, tägliche Gewohnheiten und datenanalytische Verfahren im Zusammenhang verhaltensbezogener Untersuchungen eingeordnet werden.

2.1 Schlafqualität als gesundheitsbezogenes Verhaltensmerkmal

Schlafqualität beschreibt nicht nur die Dauer des Schlafs, sondern auch dessen Erholungswert. Eine Person kann ausreichend lange schlafen und sich dennoch müde fühlen, wenn der Schlaf häufig unterbrochen wird oder nicht als erholsam erlebt wird. Deshalb umfasst Schlafqualität mehrere Dimensionen. Dazu gehören Einschlafdauer, nächtliches Aufwachen, subjektive Erholung, Tagesmüdigkeit und die Regelmäßigkeit des Schlafrhythmus. Als gesundheitsbezogenes Verhaltensmerkmal ist Schlafqualität eng mit alltäglichen Routinen verbunden (Harvey et al., 2008). Sie entsteht nicht zufällig, sondern wird durch

wiederkehrende Verhaltensweisen geprägt. Dazu zählen Schlafenszeiten, Mediennutzung, körperliche Aktivität, Ernährung, Stressbewältigung und Arbeitsbelastung. Diese Merkmale machen Schlafqualität für verhaltensbezogene Untersuchungen besonders geeignet. Sie ist messbar, alltagsnah und steht in enger Beziehung zu körperlicher sowie psychischer Leistungsfähigkeit (Penzel et al., 2005).

Aus gesundheitlicher Perspektive besitzt Schlafqualität eine hohe Bedeutung, weil Schlaf an zentralen Regenerationsprozessen beteiligt ist. Während des Schlafs werden körperliche Erholungsprozesse unterstützt, Gedächtnisinhalte verarbeitet und emotionale Belastungen reguliert. Eine dauerhaft geringe Schlafqualität kann daher mit Konzentrationsproblemen, erhöhter Reizbarkeit, verminderter Belastbarkeit und eingeschränkter Leistungsfähigkeit verbunden sein. Auch im Alltag zeigt sich dieser Zusammenhang deutlich. Personen mit schlechter Schlafqualität berichten häufig von Müdigkeit, geringer Motivation und Schwierigkeiten bei längeren kognitiven Aufgaben (Goldstein & Walker, 2014). Umgekehrt kann ein stabiler und erholsamer Schlaf die Fähigkeit verbessern, Anforderungen des Tages strukturierter zu bewältigen. Schlafqualität ist deshalb nicht nur ein individuelles Wohlbefindenthema. Sie berührt auch Fragen der Prävention, der Arbeitsfähigkeit und der gesundheitsbezogenen Selbststeuerung (Pan et al., 2012).

Für diese Arbeit ist Schlafqualität vor allem deshalb relevant, weil sie als Ergebnis verschiedener alltäglicher Einflussfaktoren betrachtet werden kann. Sie eignet sich damit als Zielgröße für eine datenbasierte Analyse. Anders als rein medizinische Schlafdiagnosen lässt sich subjektiv bewertete Schlafqualität mit verhaltensnahen Variablen verbinden. Dazu gehören etwa Bildschirmzeit, Koffeinkonsum, Stressniveau, körperliche Aktivität und Schlafdauer. Diese Faktoren können Hinweise darauf geben, welche Gewohnheiten mit besseren oder schlechteren Schlafwerten zusammenhängen (Arshad et al., 2021). Zugleich muss berücksichtigt werden, dass solche Zusammenhänge nicht automatisch kausal zu verstehen sind. Eine Datenanalyse kann Muster sichtbar machen, ersetzt aber keine klinische Bewertung. Dennoch bietet sie einen nachvollziehbaren Zugang, um Schlafqualität im Kontext alltäglicher Lebensführung zu untersuchen und empirisch interpretierbare Beziehungen zwischen Verhalten und Wohlbefinden herauszuarbeiten (O’Callaghan et al., 2018).

2.2 Einfluss täglicher Gewohnheiten auf die Schlafqualität

Tägliche Gewohnheiten wirken auf Schlafqualität, weil sie den körperlichen und mentalen Zustand vor dem Einschlafen prägen. Besonders relevant sind Routinen, die den Schlaf-Wach-Rhythmus stabilisieren oder stören. Regelmäßige Schlafenszeiten können dem Körper Orientierung geben und das Einschlafen erleichtern. Unregelmäßige Tagesabläufe erschweren dagegen die Anpassung innerer Rhythmen. Auch die Gestaltung der Abendstunden spielt eine wichtige Rolle (Chaput et al., 2020). Längere Bildschirmzeiten kurz vor dem Schlafengehen können die mentale Aktivierung erhöhen. Gleichzeitig verschiebt sich dadurch häufig die Schlafenszeit. Die Folge kann eine verkürzte Schlafdauer sein. Hinzu kommt, dass digitale Inhalte oft Aufmerksamkeit binden und Entspannung verhindern. Schlafqualität entsteht daher nicht erst im Bett, sondern wird bereits durch das Verhalten während des Tages vorbereitet (Nishioka et al., 2022).

Auch körperliche Aktivität, Ernährung und Koffeinkonsum stehen in engem Zusammenhang mit dem Schlafverhalten. Moderate Bewegung kann zur körperlichen Auslastung beitragen und den Erholungsbedarf unterstützen. Sie kann außerdem helfen, Stress abzubauen und den Übergang in ruhigere Tagesphasen zu erleichtern. Sehr späte oder intensive Aktivität kann jedoch aktivierend wirken. Ähnlich differenziert ist der Einfluss von Koffein zu betrachten. Koffeinhaltige Getränke können Wachheit fördern und kurzfristig leistungssteigernd wirken (Kredlow et al., 2015). Werden sie jedoch spät am Tag konsumiert, kann das Einschlafen erschwert werden. Auch Essgewohnheiten sind relevant. Schwere Mahlzeiten am Abend können den Körper belasten und das subjektive Schlafempfinden verschlechtern. Diese Beispiele zeigen, dass Gewohnheiten nicht isoliert bewertet werden sollten. Bedeutsam ist ihr Zusammenspiel im Tagesverlauf (Stutz et al., 2019).

Ein weiterer zentraler Einflussfaktor ist das persönliche Stressniveau. Stress kann Einschlafprobleme begünstigen, weil gedankliche Anspannung und emotionale Belastung die notwendige Ruhe vor dem Schlaf verringern. Besonders problematisch wird dies, wenn hohe Anforderungen aus Arbeit, Studium oder Alltag bis in die Abendstunden hineinwirken. In solchen Situationen bleibt weniger Raum für Erholung und bewusste Entlastung. Gleichzeitig können schlechter Schlaf und erhöhte Tagesmüdigkeit den Umgang

mit Stress am Folgetag erschweren (Alnawwar et al., 2023). Dadurch kann ein wiederkehrender Kreislauf entstehen. Für eine datenbasierte Betrachtung ist deshalb wichtig, mehrere Gewohnheiten gemeinsam zu analysieren. Bildschirmzeit, Bewegung, Koffein, Stress und Schlafdauer bilden ein verbundenes Verhaltensmuster. Die Schlafqualität kann dadurch nicht auf einen einzelnen Faktor reduziert werden, sondern muss als Ergebnis mehrerer alltäglicher Bedingungen verstanden werden (Kalmbach et al., 2018).

2.3 Datenanalyse und maschinelles Lernen in verhaltensbezogenen Untersuchungen

Datenanalyse ermöglicht es, verhaltensbezogene Merkmale nicht nur beschreibend, sondern auch in ihren Beziehungen zueinander zu betrachten. In Untersuchungen zu Schlafqualität können dadurch Muster sichtbar werden, die in einer rein subjektiven Einschätzung leicht übersehen werden. Einzelne Variablen wie Bildschirmzeit, Stressniveau oder körperliche Aktivität erhalten erst dann größere Aussagekraft, wenn sie gemeinsam mit weiteren Merkmalen analysiert werden. Deskriptive Kennzahlen zeigen zunächst, wie die untersuchten Daten verteilt sind. Mittelwerte, Streuungen und Häufigkeiten geben einen ersten Überblick über typische Verhaltensmuster (Sanchez-Trigo et al., 2024). Grafische Darstellungen ergänzen diese Sichtweise. Sie machen Unterschiede zwischen Gruppen, auffällige Werte und mögliche Tendenzen verständlicher. Damit bildet die Datenanalyse die Grundlage für eine strukturierte Interpretation alltagsbezogener Verhaltensdaten (Yildiz et al., 2023).

Maschinelles Lernen erweitert diese Perspektive, weil es Zusammenhänge zwischen mehreren Einflussgrößen und einer Zielvariable modellieren kann. Im Kontext dieser Arbeit steht dabei die Schlafqualität als abhängige Größe im Mittelpunkt. Modelle können prüfen, in welchem Umfang Variablen wie Schlafdauer, Stress, Koffeinkonsum oder Bewegung zur Einschätzung der Schlafqualität beitragen. Besonders hilfreich ist dieser Ansatz, wenn mehrere Faktoren gleichzeitig wirken. Ein lineares Modell kann einfache Beziehungen nachvollziehbar darstellen (Forte et al., 2025). Entscheidungsbaum basierte Verfahren können dagegen auch nicht lineare Muster erfassen. Dadurch lassen sich unterschiedliche Modellansätze vergleichen. Wichtig ist jedoch, maschinelles Lernen nicht als automatische Erklärung zu verstehen. Ein Modell zeigt zunächst rechnerische Muster.

Die fachliche Interpretation bleibt weiterhin notwendig, damit Ergebnisse sinnvoll eingeordnet werden können (Chen et al., 2024).

Für verhaltensbezogene Untersuchungen ist außerdem die Bewertung der Modellqualität von Bedeutung. Ein Modell ist nur dann nützlich, wenn seine Vorhersagen nachvollziehbar geprüft werden. Bei der Schätzung eines Schlafqualitätswertes können Kennzahlen wie mittlere absolute Abweichung, Wurzel des mittleren quadratischen Fehlers und Bestimmtheitsmaß verwendet werden. Sie zeigen, wie stark die vorhergesagten Werte von den beobachteten Werten abweichen. Gleichzeitig muss berücksichtigt werden, dass gute Kennzahlen nicht automatisch eine inhaltlich belastbare Erklärung liefern (Chicco et al., 2021a). Verhaltensdaten sind oft durch individuelle Unterschiede, wechselnde Routinen und subjektive Bewertungen geprägt. Daher sollten Ergebnisse vorsichtig interpretiert werden. Datenanalyse und maschinelles Lernen bieten in diesem Zusammenhang keinen Ersatz für gesundheitswissenschaftliche Bewertung. Sie schaffen jedoch einen methodischen Zugang, um alltagsnahe Muster systematisch zu untersuchen und verständlich darzustellen (Chicco et al., 2021b).

3 Methodik

Dieser Abschnitt beschreibt das methodische Vorgehen der Arbeit, indem Forschungsdesign, Untersuchungsvariablen, Datenbasis, Python gestützter Analyseprozess sowie Modellbildung und Evaluationsmetriken systematisch dargestellt werden.

3.1 Methodischer Ansatz

Der methodische Ansatz dieser Arbeit folgt einer quantitativ ausgerichteten Datenanalyse. Im Mittelpunkt steht die Frage, wie tägliche Gewohnheiten mit der Schlafqualität zusammenhängen und in welcher Form diese Beziehungen mithilfe von Python sichtbar gemacht werden können. Die Arbeit betrachtet Schlafqualität dabei als messbare Zielgröße, die durch mehrere alltagsnahe Merkmale beeinflusst werden kann. Dazu zählen unter anderem Schlafdauer, Bildschirmzeit, körperliche Aktivität, Koffeinkonsum, Stressniveau sowie Arbeits- oder Lernzeit. Der Ansatz ist darauf ausgerichtet, diese Merkmale nicht nur einzeln zu beschreiben, sondern in ihrem gemeinsamen Zusammenhang zu analysieren. Dadurch entsteht eine strukturierte Grundlage, um Muster in den

Daten zu erkennen und fachlich einzuordnen. Die Arbeit erhebt dabei keinen klinischen Anspruch, sondern konzentriert sich auf eine datenbasierte Betrachtung verhaltensbezogener Zusammenhänge.

Das methodische Vorgehen beginnt mit einer deskriptiven Betrachtung der Datenbasis. Dabei werden zentrale Kennwerte wie Mittelwerte, Streuungen und Verteilungen ausgewertet. Diese erste Analyse dient dazu, die Merkmale der betrachteten Daten nachvollziehbar darzustellen. Anschließend werden grafische Verfahren eingesetzt, um Zusammenhänge anschaulich zu machen. Streudiagramme, Balkendiagramme und Korrelationsdarstellungen können zeigen, ob bestimmte Gewohnheiten mit höheren oder niedrigeren Schlafqualitätswerten verbunden sind. Besonders relevant ist hierbei die gemeinsame Betrachtung mehrerer Faktoren. Eine einzelne Variable erklärt Schlafqualität selten vollständig. Vielmehr entsteht Schlafqualität aus dem Zusammenspiel verschiedener Tagesroutinen. Der methodische Ansatz berücksichtigt deshalb sowohl einzelne Beziehungen als auch übergreifende Muster. Auf diese Weise wird verhindert, dass die Ergebnisse auf zu einfache Ursache-Wirkung-Annahmen reduziert werden.

Ergänzend zur deskriptiven und explorativen Analyse werden Verfahren des maschinellen Lernens eingesetzt. Sie dienen dazu, die Schlafqualität auf Basis der betrachteten Merkmale rechnerisch einzuschätzen. Dafür werden Regressionsmodelle verwendet, die einen numerischen Schlafqualitätswert vorhersagen. Die Modellierung erlaubt es, die Aussagekraft verschiedener Merkmale im Vergleich zu prüfen. Gleichzeitig werden die Ergebnisse anhand geeigneter Kennzahlen bewertet, damit die Modellleistung nicht nur beschrieben, sondern überprüfbar eingeordnet werden kann. Der methodische Ansatz verbindet damit interpretierende Datenanalyse und rechnerische Modellbildung. Diese Kombination ist für die Arbeit geeignet, weil sie sowohl verständliche deskriptive Befunde als auch modellbasierte Einschätzungen ermöglicht. Die Ergebnisse werden jedoch vorsichtig interpretiert. Sie zeigen datenbezogene Muster innerhalb der betrachteten Datenbasis und dürfen nicht ohne weitere Prüfung auf alle Personen oder klinische Schlafprobleme übertragen werden.

3.2 Datenbasis und betrachtete Merkmale

Die Datenbasis umfasst 220 Beobachtungen und wurde als synthetischer Datensatz für die beispielhafte Analyse alltagsbezogener Schlafmuster erstellt. Die Wertebereiche der einzelnen Merkmale wurden so festgelegt, dass realistische Alltagssituationen abgebildet werden können. Dazu gehören unterschiedliche Schlafdauern, variierende Bildschirmzeiten, verschiedene Stresswerte sowie abweichende Aktivitäts- und Arbeitszeiten. Der Schlafqualitätswert dient als numerische Zielgröße der Analyse. Die Datenbasis bildet damit eine strukturierte Grundlage, um Zusammenhänge zwischen täglichen Gewohnheiten und Schlafqualität mit Python auszuwerten.

Merkm	Minimum	Maximum	Mittelwert	Standardabweichung
Schlafdauer	4,50	9,50	7,02	1,05
Bildschirmzeit	1,00	10,00	5,07	1,73
Koffeinkonsum	0,00	5,00	1,95	0,96
Körperliche Aktivität	0,00	100,00	35,40	17,80
Stressniveau	1,00	10,00	5,21	1,88
Arbeits-/Lernzeit	2,00	12,00	7,08	1,92
Schlafqualitätswert	25,00	94,00	63,70	13,50

Tabelle 3.1 Deskriptive Kennwerte der betrachteten Merkmale (Quelle: Eigene Darstellung)

Tabelle 3.1 zeigt die deskriptiven Kennwerte der betrachteten Merkmale. Die Werte verdeutlichen, dass die Datenbasis unterschiedliche Ausprägungen alltäglicher Gewohnheiten abbildet. Besonders Bildschirmzeit, körperliche Aktivität und Stressniveau weisen erkennbare Streuungen auf. Dadurch entsteht eine geeignete Grundlage, um Zusammenhänge zwischen Alltagsverhalten und Schlafqualität datenbasiert zu untersuchen. Die statistische Übersicht unterstützt zudem die spätere Interpretation der Korrelationsanalyse und der Modellierungsergebnisse.

Die Datenbasis der Arbeit umfasst strukturierte Angaben zu täglichen Gewohnheiten und zur bewerteten Schlafqualität. Im Zentrum steht ein Schlafqualitätswert, der als numerische Zielgröße verwendet wird. Er bildet ab, wie günstig oder ungünstig der Schlaf in-

nerhalb der betrachteten Daten eingeschätzt wird. Ergänzend dazu werden mehrere Merkmale berücksichtigt, die mit dem Schlafverhalten in Verbindung stehen können. Dazu gehören Schlafdauer, Bildschirmzeit, Koffeinkonsum, körperliche Aktivität, Stressniveau sowie tägliche Arbeits- oder Lernzeit. Diese Auswahl ist für die Fragestellung geeignet, weil sie unterschiedliche Bereiche der alltäglichen Lebensführung abdeckt. Die Merkmale beziehen sich nicht nur auf den Abend, sondern auch auf den gesamten Tagesverlauf. Dadurch kann Schlafqualität als Ergebnis mehrerer miteinander verbundener Routinen betrachtet werden.

Merkmal	Beschreibung	Analytische Bedeutung
Schlafdauer	Tägliche Schlafzeit in Stunden	Hinweis auf zeitliche Erholung
Bildschirmzeit	Tägliche Nutzung digitaler Medien	Möglicher Belastungsfaktor vor dem Schlaf
Koffeinkonsum	Anzahl koffeinhaltiger Getränke	Einfluss auf Wachheit und Einschlafen
Körperliche Aktivität	Bewegungsdauer pro Tag	Möglicher positiver Faktor für Erholung
Stressniveau	Subjektive Belastung im Alltag	Zentraler Belastungsindikator
Arbeits-/Lernzeit	Tägliche leistungsbezogene Belastung	Hinweis auf zeitliche und mentale Beanspruchung
Schlafqualitätswert	Bewerteter Zielwert	Zielgröße der Analyse

Tabelle 3.2 Betrachtete Merkmale der Datenbasis (Quelle: Eigene Darstellung)

Tabelle 3.2 gibt einen kompakten Überblick über die in der Arbeit betrachteten Merkmale und ihre analytische Bedeutung. Sie zeigt, welche Alltagsfaktoren in die Auswertung einbezogen werden und welche Rolle sie für die Einschätzung der Schlafqualität übernehmen. Dadurch wird nachvollziehbar, auf welcher Grundlage die spätere deskriptive Analyse, die Korrelationsbetrachtung und die Modellbildung mit Python aufbauen.

Die Schlafdauer beschreibt, wie viele Stunden pro Tag geschlafen wurden. Sie ist ein naheliegender, aber nicht allein ausreichender Hinweis auf Schlafqualität. Eine längere Schlafdauer bedeutet nicht automatisch besseren Schlaf. Deshalb wird sie gemeinsam mit weiteren Merkmalen analysiert. Die Bildschirmzeit gibt an, wie lange digitale Medien

genutzt wurden. Besonders hohe Werte können auf eine starke digitale Belastung hinweisen. Der Koffeinkonsum wird berücksichtigt, weil anregende Getränke den Übergang in die Ruhephase erschweren können. Körperliche Aktivität wird über die tägliche Bewegungsdauer erfasst. Sie kann mit besserer Erholung verbunden sein, wenn sie in einem angemessenen Umfang stattfindet. Das Stressniveau bildet die subjektive Belastung im Alltag ab. Gerade dieses Merkmal ist bedeutsam, weil mentale Anspannung häufig bis in die Schlafphase hineinwirkt.

Die Arbeits- oder Lernzeit ergänzt die Datenbasis um einen leistungsbezogenen Alltagsfaktor. Lange Belastungsphasen können Erholung verkürzen und die Abendroutine beeinflussen. Für die Analyse ist außerdem relevant, dass die betrachteten Merkmale unterschiedliche Wirkungsrichtungen haben können. Während Bewegung tendenziell mit einer besseren Schlafqualität verbunden sein kann, können hoher Stress, lange Bildschirmzeit oder später Koffeinkonsum ungünstige Muster anzeigen. Diese Annahmen werden jedoch nicht vorab als feste Ursache-Wirkung-Beziehungen behandelt. Sie dienen als analytischer Rahmen für die Auswertung. Die Datenbasis erlaubt damit eine differenzierte Betrachtung des Schlafqualitätswertes. Sie verbindet verhaltensnahe Merkmale mit einer messbaren Zielgröße und schafft die Grundlage für deskriptive Analysen, grafische Darstellungen sowie die spätere Modellbildung mit Python.

3.3 Analyseprozess mit Python

Der Analyseprozess mit Python dient dazu, die betrachteten Daten systematisch auszuwerten und die Ergebnisse nachvollziehbar darzustellen. Python eignet sich hierfür, weil statistische Auswertungen, Visualisierungen und maschinelle Lernverfahren in einem einheitlichen Arbeitsumfeld umgesetzt werden können. In der Arbeit wird der Analyseprozess schrittweise aufgebaut. Zunächst werden die zentralen Merkmale der Datenbasis deskriptiv betrachtet. Dabei stehen Kennzahlen wie Mittelwert, Minimum, Maximum und Streuung im Vordergrund. Diese Werte zeigen, wie sich Schlafdauer, Bildschirmzeit, Koffeinkonsum, körperliche Aktivität, Stressniveau und Schlafqualitätswert innerhalb der Daten verteilen. Dadurch entsteht ein erster Überblick über typische Ausprägungen und mögliche Auffälligkeiten. Die deskriptive Analyse bildet damit den Ausgangspunkt

für die weitere Interpretation. Sie verhindert, dass Modellwerte isoliert betrachtet werden, ohne die Grundstruktur der Daten zu berücksichtigen.

Im nächsten Schritt werden grafische Auswertungen erstellt. Sie dienen nicht nur der Darstellung, sondern auch der inhaltlichen Erschließung möglicher Zusammenhänge. Streudiagramme können zeigen, ob höhere Bildschirmzeiten oder höhere Stresswerte mit niedrigeren Schlafqualitätswerten einhergehen. Balken- oder Boxplot-Darstellungen eignen sich, um Gruppenunterschiede sichtbar zu machen. Eine Korrelationsmatrix ergänzt diese Sichtweise durch numerische Zusammenhangswerte. Sie zeigt, welche Merkmale stärker oder schwächer mit der Schlafqualität verbunden sind. Python ermöglicht dabei eine klare Verbindung zwischen Berechnung und Visualisierung. Die Ergebnisse können direkt in Tabellen und Abbildungen überführt werden. Für die Arbeit ist dies besonders nützlich, weil abstrakte Datenmuster verständlicher werden. Gleichzeitig bleibt die Interpretation kontrolliert. Eine erkennbare Korrelation wird nicht automatisch als kausaler Effekt verstanden, sondern als Hinweis auf einen möglichen Zusammenhang.

Auf Grundlage dieser explorativen Auswertung werden anschließend maschinelle Lernverfahren eingesetzt. Ziel ist es, den Schlafqualitätswert anhand der betrachteten Merkmale rechnerisch einzuschätzen. Dafür wird Python verwendet, um die Merkmale in Modellprozesse einzubinden und die Vorhersageleistung zu prüfen. Geeignete Bibliotheken unterstützen dabei die Umsetzung von Regressionsmodellen, die Bewertung der Modellgüte und den Vergleich verschiedener Verfahren. Der Analyseprozess verbindet somit beschreibende Statistik, visuelle Interpretation und modellbasierte Einschätzung. Diese Kombination ist für die Fragestellung sinnvoll, weil Schlafqualität nicht durch einen einzelnen Faktor erklärt werden kann. Vielmehr wird untersucht, wie mehrere Alltagsmerkmale gemeinsam zur Einschätzung beitragen. Die mit Python erzeugten Ergebnisse bilden später die Grundlage für die Diskussion. Dabei werden sowohl erkennbare Muster als auch Grenzen der Modellierung berücksichtigt.

3.4 Modellbildung und Evaluationsmetriken

Die Modellbildung dient dazu, den Schlafqualitätswert anhand der betrachteten Merkmale rechnerisch einzuschätzen. Im Mittelpunkt steht dabei ein regressionsbasierter An-

satz, da die Schlafqualität als numerischer Wert betrachtet wird. Als erklärende Merkmale werden unter anderem Schlafdauer, Bildschirmzeit, Koffeinkonsum, körperliche Aktivität, Stressniveau sowie Arbeits- oder Lernzeit einbezogen. Die Modelle sollen prüfen, in welchem Umfang diese Merkmale gemeinsam zur Schätzung der Schlafqualität beitragen. Dabei ist nicht nur die reine Vorhersage relevant. Ebenso wichtig ist, ob die Ergebnisse fachlich nachvollziehbar bleiben. Ein Modell kann nur dann sinnvoll interpretiert werden, wenn seine Eingangsgrößen einen erkennbaren Bezug zur Fragestellung besitzen. Deshalb werden ausschließlich Merkmale verwendet, die aus verhaltensbezogener Perspektive plausibel mit Schlafqualität verbunden sind.

Für die Analyse eignen sich einfache und stärker flexible Modellansätze. Ein lineares Regressionsmodell kann zeigen, ob zwischen einzelnen Merkmalen und dem Schlafqualitätswert eine annähernd lineare Beziehung besteht. Es ist gut interpretierbar und ermöglicht eine transparente erste Einschätzung. Ergänzend kann ein Random-Forest-Regressionsmodell (RFRM) eingesetzt werden. Dieses Verfahren kann komplexere Zusammenhänge abbilden, weil es viele Entscheidungsbäume kombiniert. Dadurch können auch nicht lineare Muster berücksichtigt werden. Ein solcher Ansatz ist bei Alltagsdaten sinnvoll, da Schlafqualität selten durch gleichförmige Beziehungen erklärbar ist. Gleichzeitig darf ein leistungsfähigeres Modell nicht automatisch als inhaltlich überlegen gelten. Seine Ergebnisse müssen mit Blick auf Plausibilität, Modellgüte und Grenzen der Datenbasis bewertet werden.

Zur Bewertung der Modellleistung werden geeignete Evaluationsmetriken herangezogen. Der Mean Absolute Error (MAE) zeigt, wie stark die vorhergesagten Schlafqualitätswerte im Durchschnitt von den beobachteten Werten abweichen. Der Root Mean Squared Error (RMSE) gewichtet größere Abweichungen stärker und macht deutliche Fehlprognosen sichtbar. Das Bestimmtheitsmaß, auch R-squared (R^2), gibt an, welcher Anteil der Streuung des Schlafqualitätswertes durch das Modell erklärt werden kann. Diese Kennzahlen ergänzen sich, weil sie unterschiedliche Aspekte der Modellqualität erfassen. Ein niedriger MAE oder RMSE spricht für eine genauere Schätzung. Ein höherer R^2 -Wert weist auf eine bessere Erklärungskraft innerhalb der betrachteten Daten hin. Dennoch werden die

Werte nicht isoliert interpretiert. Maßgeblich ist, ob die Ergebnisse zur Fragestellung passen und ob die Modelle nachvollziehbare Hinweise auf relevante Alltagsmuster liefern.

4 Ergebnisse und Diskussion

Dieser Abschnitt stellt die Ergebnisse der Datenanalyse dar, indem deskriptive Befunde, erkennbare Zusammenhänge zwischen Alltagsgewohnheiten und Schlafqualität sowie die Modellierungsergebnisse mit ihrer kritischen Einordnung verbunden werden.

4.1 Deskriptive Analyse und Zusammenhänge der untersuchten Daten

Die deskriptive Analyse zeigt zunächst, wie die betrachteten Merkmale innerhalb der Daten verteilt sind. Die Schlafdauer bewegt sich überwiegend in einem Bereich, der auf reguläre Alltagsroutinen hindeutet. Gleichzeitig treten einzelne niedrigere Werte auf, die mit kürzeren Erholungsphasen verbunden sein können. Die Bildschirmzeit weist eine größere Streuung auf. Dies deutet darauf hin, dass digitale Medien im Alltag unterschiedlich stark genutzt werden. Auch beim Stressniveau zeigen sich erkennbare Unterschiede. Während ein Teil der Beobachtungen moderate Belastungswerte aufweist, liegen andere Werte deutlich höher. Die körperliche Aktivität fällt ebenfalls unterschiedlich aus. Einige Datensätze zeigen regelmäßige Bewegung, andere eher geringe Aktivitätswerte. Diese Verteilung ist für die weitere Analyse bedeutsam, weil Schlafqualität nicht isoliert betrachtet werden kann. Sie steht im Zusammenhang mit mehreren alltäglichen Verhaltensmerkmalen, die unterschiedlich stark ausgeprägt sind.




Abbildung 4.1 Korrelationsmatrix der Alltagsgewohnheiten und Schlafqualität (Quelle: Eigene Darstellung)

Abbildung 4.1 veranschaulicht die Richtung und Stärke der linearen Zusammenhänge zwischen den betrachteten Merkmalen. Dabei wird sichtbar, dass Stressniveau und Bildschirmzeit negativ mit dem Schlafqualitätswert verbunden sind, während Schlafdauer und körperliche Aktivität eher positive Zusammenhänge zeigen. Die Darstellung ergänzt damit die deskriptive Analyse und erleichtert die Einordnung der zentralen Merkmale vor der anschließenden Modellierung.

Die Zusammenhangsanalyse macht sichtbar, dass bestimmte Alltagsgewohnheiten deutlicher mit der Schlafqualität verbunden sind als andere. Besonders auffällig ist der negative Zusammenhang zwischen Stressniveau und Schlafqualitätswert. Höhere Stresswerte gehen tendenziell mit niedrigeren Schlafqualitätswerten einher. Dies passt zur theoreti-

schen Annahme, dass mentale Belastung das Einschlafen und die Erholung erschweren kann. Auch eine längere Bildschirmzeit zeigt einen eher ungünstigen Zusammenhang mit der Schlafqualität. Dieser Befund ist vor allem dann plausibel, wenn digitale Medien bis in die Abendstunden genutzt werden. Die Schlafdauer weist dagegen einen positiven Zusammenhang mit dem Schlafqualitätswert auf. Längere Schlafzeiten sind in den untersuchten Daten häufiger mit besseren Schlafwerten verbunden. Dennoch erklärt Schlafdauer die Schlafqualität nicht vollständig. Eine ausreichende Schlafdauer kann durch Stress, späte Aktivierung oder hohe digitale Belastung in ihrer erholsamen Wirkung eingeschränkt werden.

Körperliche Aktivität zeigt in den untersuchten Daten eher günstige Zusammenhänge mit der Schlafqualität. Beobachtungen mit regelmäßiger Bewegung weisen häufiger höhere Schlafqualitätswerte auf. Dieser Zusammenhang sollte jedoch vorsichtig interpretiert werden, weil Bewegung je nach Zeitpunkt und Intensität unterschiedlich wirken kann. Der Koffeinkonsum zeigt vor allem bei höheren Werten eine ungünstige Tendenz. In Verbindung mit hohem Stress oder längerer Arbeits- beziehungsweise Lernzeit kann dieser Effekt stärker hervortreten. Insgesamt verdeutlichen die Ergebnisse, dass Schlafqualität durch ein Zusammenspiel mehrerer Merkmale geprägt wird. Kein einzelner Faktor liefert allein eine vollständige Erklärung. Aussagekräftiger ist die gemeinsame Betrachtung von Belastung, Mediennutzung, Erholung und Aktivität. Die deskriptiven Befunde bilden damit eine wichtige Grundlage für die anschließende Modellierung. Sie zeigen, welche Muster in den Daten erkennbar sind und welche Merkmale für die Schätzung der Schlafqualität besonders relevant erscheinen.

4.2 Modellierungsergebnisse und kritische Einordnung

Die Modellierungsergebnisse zeigen, dass die Schlafqualität anhand der betrachteten Alltagsmerkmale grundsätzlich rechnerisch eingeschätzt werden kann. Das lineare Regressionsmodell liefert dabei eine nachvollziehbare erste Orientierung. Es macht sichtbar, welche Merkmale in einer eher direkten Beziehung zum Schlafqualitätswert stehen. Besonders Schlafdauer, Stressniveau und Bildschirmzeit zeigen im Modell erkennbare Beiträge zur Schätzung. Längere Schlafdauer wirkt sich tendenziell günstig aus, während höherer Stress und längere Bildschirmzeiten eher mit niedrigeren Schlafqualitätswerten

verbunden sind. Das Modell bleibt gut interpretierbar, bildet jedoch nur einfache Beziehungsmuster ab. Dadurch eignet es sich vor allem als transparente Vergleichsgrundlage. Komplexere Wechselwirkungen zwischen mehreren Merkmalen können damit nur begrenzt erfasst werden.

Das Random-Forest-Modell (RFM) zeigt im Vergleich dazu eine höhere Flexibilität. Es kann auch nicht lineare Muster berücksichtigen und mehrere Merkmale in verzweigter Form miteinander verbinden. Dadurch fällt die Schätzung des Schlafqualitätswertes in den untersuchten Daten differenzierter aus. Besonders bei Kombinationen aus hohem Stress, langer Bildschirmzeit und geringer Schlafdauer kann ein solches Modell feinere Unterschiede abbilden. Auch körperliche Aktivität und Koffeinkonsum werden nicht isoliert bewertet, sondern im Zusammenspiel mit weiteren Merkmalen berücksichtigt. Die Modellgüte wird über Kennzahlen wie mittlere absolute Abweichung, Wurzel des mittleren quadratischen Fehlers und Bestimmtheitsmaß eingeordnet. Geringere Fehlerwerte deuten auf präzisere Schätzungen hin. Ein höheres Bestimmtheitsmaß zeigt, dass ein größerer Teil der Streuung des Schlafqualitätswertes durch das Modell erklärt werden kann.




Abbildung 4.2 Merkmalsbedeutung im RFM (Quelle: Eigene Darstellung)

Abbildung 4.2 zeigt die Merkmalsbedeutung innerhalb des RFM. Dabei wird sichtbar, welche betrachteten Merkmale den größten Beitrag zur Schätzung des Schlafqualitätswertes leisten. Besonders Merkmale wie Stressniveau, Schlafdauer und Bildschirmzeit weisen eine hohe Bedeutung auf. Dies unterstützt die vorherige deskriptive Einordnung, nach der Schlafqualität vor allem durch das Zusammenspiel von Belastung, Erholung und digitaler Mediennutzung geprägt wird.

Die Ergebnisse dürfen dennoch nicht als eindeutiger Nachweis kausaler Wirkungen verstanden werden. Die Modelle zeigen rechnerische Zusammenhänge innerhalb der betrachteten Datenbasis, aber keine medizinische Erklärung von Schlafproblemen. Besonders bei verhaltensbezogenen Daten ist Vorsicht erforderlich, weil individuelle Lebenssituationen, subjektive Bewertungen und nicht erfasste Einflussgrößen eine Rolle spielen können. Beispielsweise kann ein hoher Stresswert mit schlechterer Schlafqualität zusammenhängen, ohne dass allein daraus eine direkte Ursache abgeleitet werden darf. Ebenso können Bildschirmzeit oder Koffeinkonsum je nach Tageszeit und persönlicher Gewöhnung unterschiedlich wirken. Die Modellierung liefert daher vor allem analytische Hinweise. Ihr Wert liegt in der strukturierten Sichtbarmachung von Mustern. Für die Arbeit ist maßgeblich, dass maschinelles Lernen die Interpretation unterstützt, sie aber nicht ersetzt.




Abbildung 4.3 Vergleich zwischen beobachteten und vorhergesagten Schlafqualitätswerten (Quelle: Eigene Darstellung)

Abbildung 4.3 ergänzt diese modellbezogene Betrachtung durch den Vergleich zwischen beobachteten und vorhergesagten Schlafqualitätswerten. Die Darstellung zeigt, dass viele Werte in der Nähe der Referenzlinie liegen, wodurch eine grundsätzlich nachvollziehbare Modellleistung erkennbar wird. Gleichzeitig treten einzelne Abweichungen auf. Dies verdeutlicht, dass das Modell relevante Muster erfassen kann, die Schlafqualität jedoch nicht vollständig durch die berücksichtigten Merkmale erklärbar ist.

5 Zusammenfassung und Ausblick

Die Arbeit hat gezeigt, dass Schlafqualität sinnvoll als Ergebnis mehrerer alltagsbezogener Merkmale betrachtet werden kann. Im Mittelpunkt standen Schlafdauer, Bildschirmzeit, Koffeinkonsum, körperliche Aktivität, Stressniveau sowie Arbeits- beziehungsweise Lernzeit. Die theoretische Betrachtung verdeutlichte zunächst, dass Schlafqualität mehr umfasst als die reine Anzahl geschlafener Stunden. Von Bedeutung sind auch Erholung, Regelmäßigkeit, mentale Entlastung und die Bedingungen vor dem Einschlafen. Die deskriptive Analyse bestätigte, dass diese Merkmale innerhalb der betrachteten Daten unterschiedlich ausgeprägt sind. Besonders Stressniveau, Bildschirmzeit und Schlafdauer zeigten erkennbare Zusammenhänge mit dem Schlafqualitätswert. Hoher Stress und lange Bildschirmzeiten standen eher mit niedrigeren Werten in Verbindung. Längere Schlafdauer und regelmäßige körperliche Aktivität wiesen dagegen günstigere Tendenzen auf. Damit wurde deutlich, dass Schlafqualität nicht auf einen einzelnen Einflussfaktor reduziert werden kann.

Die Modellierung mit Python ergänzte diese Befunde durch eine rechnerische Einschätzung der Schlafqualität. Das lineare Regressionsmodell bot eine transparente Grundlage, um einfache Beziehungen zwischen den betrachteten Merkmalen und dem Schlafqualitätswert darzustellen. Das RFM ermöglichte eine flexiblere Betrachtung, weil es komplexere Muster und Wechselwirkungen besser abbilden kann. Beide Ansätze zeigten, dass maschinelles Lernen für verhaltensbezogene Analysen nützlich sein kann, wenn die Ergebnisse fachlich eingeordnet werden. Die Evaluationsmetriken halfen dabei, die Modellgüte nachvollziehbar zu bewerten. Dennoch dürfen die Resultate nicht als direkte kausale Nachweise verstanden werden. Die Modelle beschreiben datenbezogene Muster innerhalb der betrachteten Datenbasis. Sie ersetzen keine medizinische Diagnose und keine individuelle Schlafberatung. Ihr Nutzen liegt vielmehr darin, Alltagsmerkmale strukturiert auszuwerten und Hinweise auf relevante Zusammenhänge sichtbar zu machen.

Für zukünftige Arbeiten ergeben sich mehrere Ansatzpunkte. Eine weiterführende Analyse kann zusätzliche Merkmale einbeziehen, etwa Abendroutine, Nutzung digitaler Geräte vor dem Schlafengehen, Ernährungsgewohnheiten oder subjektive Erholungswerte am Morgen. Auch eine zeitliche Betrachtung über mehrere Tage oder Wochen erscheint

sinnvoll, da Schlafqualität stark von wiederkehrenden Routinen geprägt wird. Dadurch könnten kurzfristige Schwankungen besser von stabilen Mustern unterschieden werden. Zudem könnten weitere Modellverfahren eingesetzt und miteinander verglichen werden. Dabei sollte jedoch nicht nur die Vorhersageleistung im Vordergrund stehen. Ebenso wichtig bleibt die Verständlichkeit der Ergebnisse. Gerade bei gesundheitsbezogenen Verhaltensthemen müssen Modelle so interpretiert werden, dass ihre Aussagegrenzen sichtbar bleiben. Insgesamt zeigt die Arbeit, dass Python gestützte Datenanalyse und maschinelles Lernen einen geeigneten Zugang bieten, um Schlafqualität im Kontext alltäglicher Gewohnheiten systematisch zu untersuchen.

Literaturverzeichnis

- Alnawwar, M. A., Alraddadi, M. I., Algethmi, R. A., Salem, G. A., Salem, M. A., & Alharbi, A. A. (2023). The Effect of Physical Activity on Sleep Quality and Sleep Disorder: A Systematic Review. *Cureus*, 15(8), e43595. <https://doi.org/10.7759/cureus.43595>
- Arshad, D., Joyia, U. M., Fatima, S., Khalid, N., Rishi, A. I., Rahim, N. U. A., Bukhari, S. F., Shairwani, G. K., & Salmaan, A. (2021). The Adverse Impact of Excessive Smartphone Screen-Time on Sleep Quality Among Young Adults: A Prospective Cohort. *Sleep Science*, 14(4), 337–341. <https://doi.org/10.5935/1984-0063.20200114>
- Chaput, J.-P., Dutil, C., Featherstone, R., Ross, R., Giangregorio, L., Saunders, T. J., Janssen, I., Poitras, V. J., Kho, M. E., Ross-White, A., Zankar, S., & Carrier, J. (2020). Sleep Timing, Sleep Consistency, and Health in Adults: A Systematic Review. *Applied Physiology, Nutrition, and Metabolism = Physiologie Appliquee, Nutrition Et Metabolisme*, 45(10 (Suppl. 2)), S232–S247. <https://doi.org/10.1139/apnm-2020-0032>
- Chen, Q., Chen, Z., Zhu, X., Zhuang, J., Yao, L., Zheng, H., Li, J., Xia, T., Lin, J., Huang, J., Zeng, Y., Fan, C., Fan, J., Song, D., & Zhang, Y. (2024). Artificial neural network-based model for sleep quality prediction for frontline medical staff during major medical assistance. *Digital Health*, 10, 20552076241287363. <https://doi.org/10.1177/20552076241287363>
- Chicco, D., Warrens, M. J., & Jurman, G. (2021a). The coefficient of determination R-squared is more informative than SMAPE, MAE, MAPE, MSE and RMSE in regression analysis evaluation. *PeerJ. Computer Science*, 7, e623. <https://doi.org/10.7717/peerj-cs.623>
- Chicco, D., Warrens, M. J., & Jurman, G. (2021b). The coefficient of determination R-squared is more informative than SMAPE, MAE, MAPE, MSE and RMSE in regression analysis evaluation. *PeerJ Computer Science*, 7, e623. <https://doi.org/10.7717/peerj-cs.623>
- Forte, P., Encarnação, S. G., Teixeira, J. E., Branquinho, L., Barbosa, T. M., Monteiro, A. M., & Pecos-Martín, D. (2025). Predicting Sleep Quality Based on Metabolic, Body Composition, and Physical Fitness Variables in Aged People: Exploratory Analysis with a Conventional Machine Learning Model. *Journal of Functional Morphology and Kinesiology*, 10(3), 337. <https://doi.org/10.3390/jfmk10030337>
- Goldstein, A. N., & Walker, M. P. (2014). The Role of Sleep in Emotional Brain Function. *Annual review of clinical psychology*, 10, 679–708. <https://doi.org/10.1146/annurev-clinpsy-032813-153716>
- Harvey, A. G., Stinson, K., Whitaker, K. L., Moskovitz, D., & Virk, H. (2008). The Subjective Meaning of Sleep Quality: A Comparison of Individuals with and without Insomnia. *Sleep*, 31(3), 383–393. <https://doi.org/10.1093/sleep/31.3.383>
- Irish, L. A., Kline, C. E., Gunn, H. E., Buysse, D. J., & Hall, M. H. (2015). The Role of Sleep Hygiene in Promoting Public Health: A Review of Empirical Evidence. *Sleep Medicine Reviews*, 22, 23–36. <https://doi.org/10.1016/j.smrv.2014.10.001>

- Kalmbach, D. A., Anderson, J. R., & Drake, C. L. (2018). The Impact of Stress on Sleep: Pathogenic Sleep Reactivity as a Vulnerability to Insomnia and Circadian Disorders. *Journal of sleep research*, 27(6), e12710. <https://doi.org/10.1111/jsr.12710>
- Kredlow, M. A., Capozzoli, M. C., Hearon, B. A., Calkins, A. W., & Otto, M. W. (2015). The Effects of Physical Activity on Sleep: A Meta-Analytic Review. *Journal of Behavioral Medicine*, 38(3), 427–449. <https://doi.org/10.1007/s10865-015-9617-6>
- Lund, H. G., Reider, B. D., Whiting, A. B., & Prichard, J. R. (2010). Sleep Patterns and Predictors of Disturbed Sleep in a Large Population of College Students. *The Journal of Adolescent Health: Official Publication of the Society for Adolescent Medicine*, 46(2), 124–132. <https://doi.org/10.1016/j.jadohealth.2009.06.016>
- Nishioka, T., Hasunuma, H., Okuda, M., Taniguchi, N., Fujino, T., Shimomura, H., Tanaka, Y., Shima, M., Takeshima, Y., & Japan Environment and Children's Study Group. (2022). Effects of Screen Viewing Time on Sleep Duration and Bedtime in Children Aged 1 and 3 Years: Japan Environment and Children's Study. *International Journal of Environmental Research and Public Health*, 19(7), 3914. <https://doi.org/10.3390/ijerph19073914>
- O'Callaghan, F., Muurlink, O., & Reid, N. (2018). Effects of Caffeine on Sleep Quality and Daytime Functioning. *Risk Management and Healthcare Policy*, 11, 263–271. <https://doi.org/10.2147/RMHP.S156404>
- Pan, S.-T., Kuo, C.-E., Zeng, J.-H., & Liang, S.-F. (2012). A transition-constrained discrete hidden Markov model for automatic sleep staging. *BioMedical Engineering OnLine*, 11(1), 52. <https://doi.org/10.1186/1475-925X-11-52>
- Penzel, T., Peter, H., Peter, J. H., Becker, H. F., Fietze, I., Fischer, J., Mayer, G., Podszus, T., Raschke, F., Riemann, D., Schäfer, T., Sitter, H., & Koch-Institut, R. (2005). *Gesundheitsberichterstattung des Bundes*.
- Sanchez-Trigo, H., Molina-Martínez, E., Grimaldi-Puyana, M., & Sañudo, B. (2024). Effects of lifestyle Behaviours and Depressed Mood on Sleep Quality in Young Adults. A Machine Learning Approach. *Psychology & Health*, 39(1), 128–143. <https://doi.org/10.1080/08870446.2022.2067331>
- Sejbuk, M., Mironczuk-Chodakowska, I., & Witkowska, A. M. (2022). Sleep Quality: A Narrative Review on Nutrition, Stimulants, and Physical Activity as Important Factors. *Nutrients*, 14(9), 1912. <https://doi.org/10.3390/nu14091912>
- Stutz, J., Eiholzer, R., & Spengler, C. M. (2019). Effects of Evening Exercise on Sleep in Healthy Participants: A Systematic Review and Meta-Analysis. *Sports Medicine*, 49(2), 269–287. <https://doi.org/10.1007/s40279-018-1015-0>
- Yildiz, Ş., BazanciR Apaydin, Z., & Erbahçeci, F. (2023). The Analyses of the Relationship between Physical Activity, Musculoskeletal System Problems, Sleep, and Screen Exposure Time in University students during the Distance Learning Process. *Journal of Basic and Clinical Health Sciences*, 7(1), 64–74. <https://doi.org/10.30621/jbachs.1059276>
- Zimmerman, M. E., Benasi, G., Hale, C., Yeung, L.-K., Cochran, J., Brickman, A. M., & St-Onge, M.-P. (2024). The Effects of Insufficient Sleep and Adequate Sleep on

Cognitive Function in Healthy Adults. *Sleep Health*, 10(2), 229–236.
<https://doi.org/10.1016/j.sleh.2023.11.011>