

ウェアラブルセンサを用いた頭皮ケア支援システム

MAO HAOMIN¹ 磯山 直也² 寺田 努¹ 塚本昌彦¹

概要：頭皮は環境の温湿度に敏感であるため、適切に頭皮ケアをするには頭皮の状態を測定し、把握することが重要である。頭皮の状態に影響する要素としては、頭皮温度、頭皮水分量、環境湿度が挙げられるが、これらの日常生活の中で変化していくため、常時測定し、情報を得る必要がある。そこで、本研究ではウェアラブルセンサを用いて、頭皮の状態を常時計測し、得られた情報をユーザにフィードバックする頭皮ケア支援システムを提案する。頭皮温度と環境湿度は小型の温度センサと湿度センサにより計測可能であるが、頭皮水分量を常時計測可能な装置は存在していない。水質測定器として使われる TDS センサで頭皮導電率を測定することにより、頭皮水分量を算出できるが、TDS センサは装着感が不快であり、日常生活での使用には向いていない。そこで、生体温熱モデルに基づいて頭皮水分量を推定する。提案システムを構築するために、まずデータ収集デバイスがウェアラブルセンサを用いて各実環境で頭皮のデータを取得し、回帰モデルを訓練する。そして、提案システムに訓練済みのモデルを導入して、推定した頭皮水分量と他の情報をユーザに提示する。実験では、推定誤差、回帰精度 (R² スコア)、過学習の度合いから各回帰モデルを評価した。

1. はじめに

髪を適切な状態に保つために、ヘアケアを行うことは大切であるが、人間の頭皮は髪の土壌と言い、ヘアケアより頭皮ケアを優先すべきだと考えられる [1]。髪は頭皮の温度や水分量の影響を受けやすく、頭皮にダメージを与えられると抜け毛やフケなどが発生する。周囲の温湿度状況、仕事上のストレス、バランスの撮れていない食事、生活習慣の乱れなどにより頭皮の状態は常時変化するため、頭皮の情報を常時計測出来ることが求められる。頭皮状態について、頭皮温度と頭皮水分量を把握することが特に重要である。頭皮の温度は個人差があるが、基本的に人間の体温より 1-3°C 低い程度が最適であるとされている。頭皮温度がこれより低い場合は、頭皮の血行が低下して十分な酸素が運ばれず、周辺に毒素が蓄積され、髪の生長が妨害される。頭皮温度が高い場合は、痒みや痛みなどの炎症が起こりやすく、頭皮が病気になる可能性もある。頭皮水分量は 15-20% が望ましいとされ、10% を切ると頭皮が乾燥状態になるため、髪が脱毛する。一般的に頭皮水分量は 40% 以上にならないが、頭皮水分量は環境湿度の間接影響により変化するので、高湿度の環境下ではカビや雑菌が繁殖しやすく、皮脂の分泌が活発になり、フケが生成されて頭皮も臭くなる。また、環境湿度は 40% を下回ると静電気が発

生しやすくなり、頭皮表面での損傷が生じやすい。そのため、環境湿度を 60-65% に保つことが重要である。頭皮温度、頭皮水分量、環境湿度を適切に保つことができれば、頭皮の血行が促進されることで髪に栄養素が届きやすくなるため、頭皮を健康な状態にできる。

頭皮水分量を測定するためには、肌状態を計測するセンサ [2] を利用できるが、気温などの外乱に弱く、測定値が正確ではない。水分蒸散量計、高感度角層膜厚・水分計 [3] などを用いることで正確に頭皮情報を取得できるが、高価であり、大型であるため日常的な測定には不向きである。そこで、本稿ではウェアラブルセンサを用いて頭皮情報を常時認識し、ユーザに頭皮状況を提示する支援システムを提案する。

2. 提案手法

頭皮ケアには頭皮温度、頭皮水分量、環境湿度の常時計測は重要であり、頭皮温度と環境湿度は温度センサと湿度センサによりそれぞれ取得できる。しかし、頭皮水分量は常時計測できるセンサが存在しない。本章では頭皮水分量の認識手法や生体温熱モデルにおける日常測定のための頭皮水分量推定手法を述べる。

2.1 頭皮水分量の認識手法

頭皮水分量は頭皮誘電率と頭皮導電率 [4] から求められるが、頭皮水分量の変化は主に頭皮導電率の変化によるも

¹ 神戸大学大学院工学研究科

² 奈良先端科学技術大学院大学

のであるため、TDS センサで頭皮導電率を測定する。頭皮水分量は式 (1) によって算出する。M は頭皮水分量、 α 、 β は定数であり、 σ は実測導電率で σ' は飽和導電率である。TDS センサは金属探針と頭皮接触時の電圧変化から導電率を計測するが、金属探針を頭皮に長時間触れさせておくことはユーザに不快感を与える。そこで、次節において生体温熱モデルにより頭皮水分量の推定する手法について説明する。

$$M = \alpha * \left(\frac{\sigma}{\sigma'}\right)^\beta * 100\% \quad (1)$$

2.2 生体温熱モデル

生体温熱モデルは人体での熱交換や熱収支に関する物理量の関係を表すモデルである。生体温熱モデルの1つとして Gagge らが 1971 年に提唱した 2 ノードモデル [5] が存在する。このモデルは人体を皮膚層と深部層の 2 層構造に想定し、体温、発汗量などの熱交換から生じた生体データを数式に表す。ノードは人体部位の分割数であり、分割数が多いほど、モデルの精度が高くなる。Stolwijk の 25 ノードモデル [6] により人体熱交換過程を詳しく表示できるが、生体データを測定するには大量のセンサが使用し、その膨大なデータ整合は複雑であるため、モデルの構築も困難である。しかし、これらの生体温熱モデルから人間の頭部だけにおいても、頭皮温度と頭皮水分量の間には関係が存在すると考えられる。そこで、頭部温熱モデルの構築を回避し、本稿では回帰モデルを用い、回帰分析により頭皮水分量を推定する。回帰モデルの入出力は 2 ノードモデルを参照する。2 ノードモデルでは個人差パラメータ（身長、体重、年齢、性別）、環境状況、生体状況 [7] の 3 種類のデータから人内部の熱交換を決定するが、本稿では 1 人に対するシステムによって評価を行うため、個人差パラメータの影響を考慮せず、環境温度、環境湿度、頭皮表面温度、人体深部温度（体温）、心拍数を回帰モデルの入力量とし、頭皮水分量を出力量とする。また、回帰モデルはモデルの種類により回帰精度が異なるため、実験ではいくつかの代表的な回帰モデルを用い、評価実験を行う。

3. 提案システム

提案システムを構築するために、まず TDS センサを用いた際のデータを収集し、回帰モデルを作成する必要がある。データ収集に用いるデバイスの外観と装着した様子を図 1 に示す。帽子内にマイコンとして ArduinoNano、無線通信モジュールとして XBee、頭皮温度測定用温度センサ、深部温度測定用温度センサ、環境温湿度測定用温湿度センサ、心拍センサ、TDS センサを装着する。データ測定時は XBee により PC と通信し、PC 上にデータを記録する。頭皮水分量は環境温湿度に影響されやすいため、データ測定は複数の実環境で頭皮情報を収集する必要がある。




図 1: データ収集用デバイス




図 2: 頭皮ケア支援デバイス

データ収集後それぞれの実環境のデータを用い、Python によるプログラミングすることが可能な統合開発環境である Spyder を用いて回帰分析を行う。回帰分析には複数の回帰モデルを比較し、最も優れているモデルを頭皮ケア支援システムに使用する。

提案システムにおけるユーザが装着するデバイスの外観と装着した様子を図 2 に示す。帽子の中にマイコンとして ArduinoNano、Bluetooth モジュールとして RN-42、頭皮温度測定用温度センサ、深部温度測定用温度センサ、環境温湿度測定用温湿度センサ、心拍センサを装着する。本デバイスは常時測定したデータをスマートフォン上で操作するアプリケーションに送信し、アプリケーションは導入された回帰モデルにより頭皮水分量を計算する。図 3 はスマートフォンアプリケーションのスクリーンショットであり、頭皮温度、頭皮水分量、環境湿度をそれぞれの部分に表示する。また、この 3 つのデータにより頭皮健康のためのアドバイスをユーザに提示する。アドバイスの内容は以下に示す。

- 頭皮温度が 30°C より低い場合：頭皮マッサージはおすすめします。
- 頭皮温度が 38°C より高い場合：頭皮炎症に要注意です。できれば診断を受けてください。
- 環境湿度が 40% より低い場合：加湿器の使用をおすすめします。
- 環境湿度が 65% より高い場合：室内ではエアコンで除湿をしてください、室外では移動をおすすめします。
- 頭皮水分量が 10% より低い場合：適切なシャンプーの利用をおすすめします。
- 頭皮水分量が 30% より高い場合：シャワーまたはお風呂を控えてください。

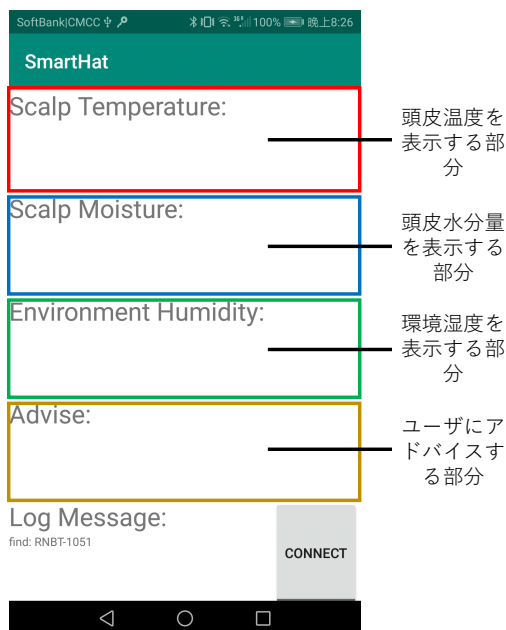


図 3: スマートフォンアプリケーションのスクリーンショット

4. 実験

本章では頭皮データ収集方法、回帰モデル作成の予備調査、回帰モデルの作成を述べる。

4.1 データ収集方法


被験者 1 人（第一著者）が電車、地下鉄、公園、飲食街、海辺、ショッピングモール、商店街、道端（昼と夜）の 8ヶ所で頭皮データを取得した。被験者は各地点でデータ収集デバイスを被って 15 分間静止する。最初の 5 分間のデータは不安定であるため使用せず、残りの 10 分間のデータを評価実験に用いる。各センサ値は 2Hz で保存する。計測後のデータから外れ値を取り除き、外れ値が記録されたタイミングでは他のセンサ値も取り除いた。

4.2 回帰モデル作成の予備調査

線形モデル、多項式回帰モデル、RBF ネットワーク（放射基底関数）、ニューラルネットワークの 4 つのモデルを使い、推定誤差、R2 スコア、過学習の度合いから各回帰モデルを評価した。推定誤差は頭皮水分量の実測値と推定値の差の絶対値の平均値である。R2 スコアは 1 に近いほど、モデルの回帰精度が高いことを示している。過学習の度合いは K-分割交差検証法を使用し、推定正確度と交差検証の正確度の差の絶対値の平均値から判断する。K 値は 10 とする。評価結果を表 1 に、実測値曲線と各回帰モデルの推定曲線を図 4 に示す。推定曲線はそれぞれのモデルに対して、回帰分析から得られた推定値の 100 個データを抜粋した曲線である。各回帰モデルは scikit-learn において作成

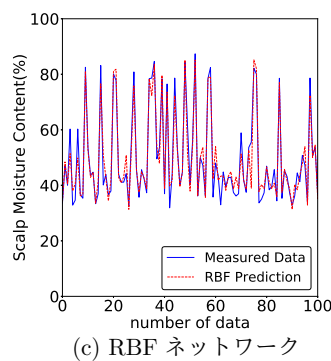
表 1: 予備調査での結果

モデル	推定誤差 [%]	R2 スコア	過学習の度合い [%]
線形モデル	10.49	0.42	15.61
多項式回帰モデル	11.08	-19.09	8070.67
RBF ネットワーク	2.85	0.86	21.74
ニューラルネットワーク	NaN	NaN	NaN



(a) 線形モデル

(b) 多項式回帰モデル



(c) RBF ネットワーク

図 4: 実測値曲線とモデルの推定曲線

したほか、ニューラルネットワークは活性化関数を ReLU、最適化方法を勾配降下法と設定した。

線形モデルと多項式回帰モデルの推定誤差が大きい結果となった。多項式回帰モデルの過学習の度合いは相当高く、頭皮水分量を正しく推定できていないと考えられる。RBF ネットワークの推定誤差が最小で、R2 スコアが最大であり、現段階での回帰性能は最も優れている。ニューラルネットワークは最適解が見つからず、結果と推定曲線を得られていない。各学習モデルからある程度の過学習現象が見られたため、日常測定に応用する前にさらに調整する必要がある。また、線形モデル以外では計算時間が長いいため、特徴量エンジニアリングにおいて測定データを変換するほか、各回帰モデルのパラメータを調整し、改良を行う。

4.3 回帰モデルの作成

特徴量エンジニアリングはデータの主要な特徴量を保ち

表 2: 評価結果

モデル	推定誤差 [%]	R2 スコア	過学習の 度合い [%]
線形モデル	10.87	0.36	4.58
多項式回帰モデル	7.92	0.49	2056.41
RBF ネットワーク	4.09	0.84	8.91
ニューラル ネットワーク	2.27	0.95	39.24

つつ、広い数値範囲をもつデータを小さい区間に変換させ、誤差特徴の影響または物理量の単位の影響を削減できる。いくつかの方法があるが、本稿では Z スコア標準化を使用した。Z スコア標準化の公式は式 (2) になり、 X , μ , σ それぞれは元データ、元データの平均値、元データの標準偏差である。Z スコア標準化は入力データのみに対し使う。

$$Z = \frac{X - \mu}{\sigma} \quad (2)$$

多項式回帰モデルの回帰精度を上げるため、モデルの回帰次数を増加した。また、ニューラルネットワークの最適化方法を Adam に変更する。評価結果を表 2 に、実測値曲線と各学習モデルの推定曲線を図 5 に示す。

Z スコア標準化前後では他のモデルには効果があるが、線形モデルの結果が変化を見られていない。その原因はモデルの入力と出力が非線形関係があるため、線形モデルは非線形関係の回帰に適用されず、入力データを標準化しても出力に影響しない。多項式回帰モデルと RBF ネットワークは過学習の度合いは減少したが、十分な推定結果は得られていない。多項式回帰モデルに対して回帰次数を 5 までに増加すると、大きくバラつきが生じるため、データの特徴量を適切に認識できず、使用に適していない。Z スコア標準化によりニューラルネットワークの結果を収束させられたが、過学習の度合いが高く、常時測定に使用できない。ニューラルネットワークの中間層の層数や中間層のニューロン数の調整も試みたが、結果は変化しなかった。これはデータ特徴量が全てのニューロンを通ったが、多くのニューロンの活性が低く、その特徴量の一部だけが出力までに伝達したため、ニューラルネットワークは局所最適解に陥ったと考えられる。それを解決するため、Batch Normalization[8] を用いる。

Batch Normalization は深層ニューラルネットワークの収束不能問題を解決するための方法である。Z スコア標準化と違い、モデルの入力データを標準化し、ニューラルネットワークの入力層から最後の中間層まで全てのニューロンの出力を標準化する。これより多くのニューロンが活性化するため、ニューラルネットワークが局所解を回避し、素早く全局最適解に辿り着ける。表 3 に Batch Normalization を用いた際の評価結果を示す。推定誤差は増えたが、過学習は抑えられた。実測値曲線と Batch Normalization での

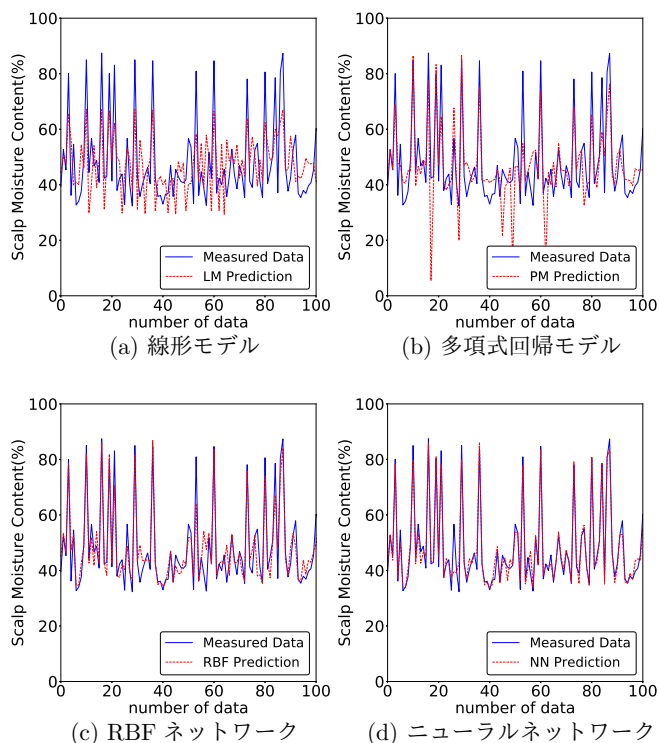


図 5: 実測値曲線とパラメータ調整後のモデル推定曲線

表 3: Batch Normalization での評価結果

モデル	推定誤差 [%]	R2 スコア	過学習の 度合い [%]
ニューラル ネットワーク	3.19	0.91	6.46

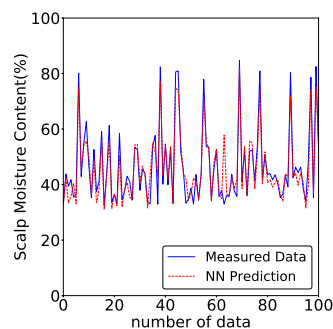


図 6: 実測値曲線と Batch Normalization でのニューラルネットワーク推定曲線

推定曲線を図 6 に示す。上記 4 つの回帰モデルを比較する結果により、ニューラルネットワークが最も正確に頭皮水分量を推定できることがわかり、提案システムではニューラルネットワークを用いる。

4.4 考察

頭皮水分量の結果について、評価実験時の実測値曲線から、その値が 40-80% となっている。頭皮水分量は 40% を

超えることはほとんどないとされているため、正解データとなる実測値の誤差が大きい可能性がある。推定されたデータは実測値に依存するため、TDS センサを用いた頭皮水分量の推定算式を検討する必要がある。

人体の深部温は温度センサで耳の奥に配置していただく、しっかりと固定することが難しかったため、他の鼓膜温を取得できるセンサについて検討する必要がある。データ収集時には、15分のデータだけを取得したが、文献[9][10]より日常での長時間使用には帽子内環境が変化していることが明らかにされており、短時間の測定では回帰モデルからの推定誤差が徐々に大きくなるため、データ収集デバイスにおける長時間測定のデータが必要である。

5. おわりに

本稿ではウェアラブルセンサを用いた頭皮ケアシステムを提案した。TDS センサにより得られた頭皮導電率をもとに、環境温度、環境湿度、頭皮表面温度、人体深部温度(体温)、心拍数から回帰分析により、頭皮水分量を推定した。4つの回帰モデルを比較し、ニューラルネットワークの性能が最も良い結果を得られた。

今後の課題としては頭皮水分量の計算方法はシステムの精度を大きく影響するため、より正確な計算方法を検討する必要がある。正確なデータを収集するために、より適切なウェアラブルセンサについての検討も行う。また、生体温熱モデルでは個人差が重要なパラメータでとなるため、今後は被験者を増やし、個人差に対応できるシステムを作成する。

謝辞 本研究の一部は、JST CREST(JPMJCR16E1, JPMJCR18A3), NICT(アジャイル型共創による高齢者補助ロボット用ネットワークプラットフォーム技術の研究開発)の支援によるものである。ここに記して謝意を表す。

参考文献

- [1] 永山升三, 西尾宏: ヘアケアの科学, 繊維製品消費科学, Vol. 28, No. 6, pp. 219-226 (1987).
- [2] 美ルル スキンチェッカー 肌チェッカー, 入手先 (<https://www.amazon.co.jp/dp/B06WXX5ZXV/>).
- [3] 高感度角層膜厚・水分計 ASA-MX100, 入手先 (<https://www.j-asch.co.jp/category/cn5/cn3/asa-mx100.html>).
- [4] 藤原 修, 高井清文: 皮膚組織の電気定数と頭部リアルモデルにおけるマイクロ波の比吸収率計算, 電気学会論文誌 C, Vol. 117, No. 1, pp. 75-80 (1997).
- [5] Gagge, A., et al.: An Effective Temperature Scale Based on a Simple Model of Human Physiological Regulatory Response, *ASHRAE Trans.*, Vol. 77, No. 2192, pp. 247-262 (1971).
- [6] Stolwijk, J. A., et al.: A Mathematical Model of Physiological Temperature Regulation in Man, *National Aeronautics and Space Administration*, Vol. 1855, No. NAS 9-9531 (1971).
- [7] 濱谷尚志, 内山 彰, 東野輝夫: ウェアラブルセンサと生体温熱モデルを用いた暑熱環境下での深部体温推定の一手

法, 情報処理学会論文誌, Vol. 56, No. 10, pp. 2033-2043 (2015).

- [8] Loffe, S. and Szegedy, C.: Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift, *In Proc. of the 32nd International Conference on Machine Learning*, pp. 448-456 (2015).
- [9] 緑川知子, 登倉尋寶: 寒冷環境下における帽子着用が深部体温に与える影響, 日本家政学会誌, Vol. 45, No. 4, pp. 323-330 (1994).
- [10] 緑川知子, 登倉尋寶: 暑熱放射熱存在下における帽子着用が温熱生理反応に与える効果, 日本家政学会誌, Vol. 43, No. 5, pp. 421-427 (1992).